



TESIS - SS14 2501

**MODEL *HYBRID* ARIMAX-QR DAN QRNN UNTUK PERAMALAN  
*INFLOW* DAN *OUTFLOW* UANG KARTAL DI BANK INDONESIA  
PROVINSI NTT DAN NASIONAL**

**AGNES ONA BLITI PUKA  
NRP. 1315 201 010**

**DOSEN PEMBIMBING  
Dr. Suhartono, M.Sc  
Dr.rer.pol. Dedy Dwi Prastyo, M.Si**

**PROGRAM MAGISTER  
JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2017**



**TESIS - SS14 2501**

**HYBRID ARIMAX-QR AND QRNN MODEL FOR FORECASTING  
CURRENCY INFLOW AND OUTFLOW AT BANK INDONESIA IN  
NTT PROVINCE AND NATIONAL LEVEL**

**AGNES ONA BLITI PUKA  
NRP. 1315 201 010**

**SUPERVISOR  
Dr. Suhartono, M.Sc  
Dr.rer.pol. Dedy Dwi Prastyo, M.Si**

**PROGRAM OF MAGISTER  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS AND NATURAL SCIENCE  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2017**


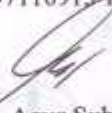
**MODEL HYBRID ARIMAX-QR DAN QRNN UNTUK PERAMALAN  
INFLOW DAN OUTFLOW UANG KARTAL DI BANK INDONESIA  
PROVINSI NTT DAN NASIONAL**

Disusun untuk memenuhi syarat memperoleh gelar Magister Sains (M.Si)  
di  
Institut Teknologi Sepuluh Nopember

Oleh :  
**AGNES ONA BLITI PUKA**  
**NRP. 1315 2010 10**

Tanggal Ujian : 20 Juli 2017  
Periode Wisuda : September 2017

Disetujui Oleh :

1.   
Dr. Suhartono, M.Sc (Pembimbing I)  
NIP. 19710929 199512 1 001
2.   
Dr. rer.pol. Dedy Dwi Prastyo, M.Si (Pembimbing II)  
NIP. 19831204 200812 1 002
3.   
Dr. R. Moh. Atok, M.Si (Penguji I)  
NIP. 197110915 199702 1 001
4.   
Dr. Drs. Agus Suharsono, MS (Penguji II)  
NIP. 19580823 198403 1 003

Dekan  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember  
  
Prof. Dr. Basuki Widodo, M.Sc  
NIP. 19650605 198903 1 002



# **Model *Hybrid* ARIMAX-QR dan QRNN Untuk Peramalan *Inflow* dan *Outflow* Uang Kartal di Bank Indonesia Provinsi NTT dan Nasional**

Nama Mahasiswa : Agnes Ona Bliti Puka  
NRP : 1315 201 010  
Pembimbing I : Dr. Suhartono, M.Sc  
Pembimbing 2 : Dr.rer.pol Dedy Dwi Prastyo, M.Si

## **ABSTRAK**

Permasalahan yang sering ditemui dalam peramalan *time series* adalah linearitas, nonlinearitas dan heteroskedastisitas. Metode untuk menganalisis permasalahan tersebut diantaranya metode *Autoregressive Integrated Moving Average* (ARIMA), *Neural Network* (NN) dan *Quantile Regression* (QR). Terdapat banyak penelitian dan pengembangan mengenai metode tersebut, namun penelitian mengenai perbandingan kinerja dari *hybrid* metode tersebut dalam menyelesaikan kasus data real masih terbatas. Oleh karena itu, penelitian ini dilakukan perbandingan kinerja antara metode *hybrid* ARIMAX-QR dan *quantile Regression Neural Network* (QRNN). Kedua metode digunakan pada studi kasus peramalan *inflow* dan *outflow* uang kartal Bank Indonesia Provinsi Nusa Tenggara Timur dan Nasional. Metode terbaik ditentukan berdasarkan kriteria *Root Mean Squared Error* (RMSE) dan Median Absolute Error (MdAE) terkecil.

Berdasarkan studi kasus, metode ARIMAX menghasilkan RMSE dan MDAE *out-sample* terkecil untuk *inflow* uang kartal BI provinsi NTT sebesar 59,861 dan 36,122, sedangkan untuk *outflow* uang kartal BI provinsi NTT dan *inflow* serta *outflow* tingkat Nasional metode QRNN menghasilkan RMSE *out-sample* terkecil sebesar 99,009; 11340,110 dan 14786,96. Hasil tersebut menunjukkan bahwa metode ARIMAX memberikan kinerja peramalan lebih baik untuk meramalkan data *inflow* uang kartal Provinsi NTT yang bersifat heterogen linear. Sedangkan metode *hybrid* QRNN memberikan kinerja peramalan lebih baik untuk meramalkan data *outflow* uang kartal Provinsi NTT, data *inflow* serta *outflow* tingkat Nasional yang bersifat heterogen nonlinear.

**Kata Kunci :** ARIMAX, Neural Network , *Quantiles Regression*, dan Model *hybrid*

*(Halaman ini sengaja dikosongkan)*

# **Hybrid ARIMAX-QR and QRNN Model for Forecasting Currency Inflow and Outflow at Bank Indonesia in NTT Province and National Regional**

Name : Agnes Ona Bliti Puka  
Student Id. Number : 1315 201 010  
Supervisor : Dr. Suhartono, M.Sc  
Co- supervisor : Dr.rer.pol Dedy Dwi Prastyo, M.Si

## **ABSTRACT**

The main problem that be frequently arise in time series analysis are nonlinearity and heteroscedasticity. There are some methods that could be used for analyzing these problems are *Autoregressive Integrated Moving Average* (ARIMA), *Neural Network* (NN) dan *Quantile Regression* (QR). There are a lot of researches and development on these methods, but the research focusing on performance comparison between the two methods applied in real case is still limited. Therefore, this study focuses on comparison between hybrid ARIMAX-QR, Quantile Regression Neural Network (QRNN) and ARIMAX. All methods are employed for modeling and forecasting the currency inflow and outflow data in Bank Indonesia.

The results show that, ARIMAX method produced the smallest RMSE and MDAE out-samples for currency inflow in NTT province about 59.861 and 36.122, respectively. While for the currency outflow in NTT province and the national rate inflow and outflow, QRNN method resulted in the smallest RMSE out-sample of 99.009, 11340.110 and 14786.96, respectively. These results indicate that the ARIMAX method provides better forecasting performance for predicting the homogeneous linear data in currency inflow at NTT province. The QRNN hybrid method provides more accurate performance to forecast both currency outflow that contain non-linear heterogeneous data in NTT province and currency inflow and outflow data in National.

**Keywords:** Time Series Regression; ARIMAX; Neural Network; QRNN

*(Halaman ini sengaja dikosongkan)*

## KATA PENGANTAR

Puji dan syukur penulis panjatkan kehadirat Tuhan Yang Maha Esa, karena dengan rahmat-Nya, penulis dapat menyelesaikan tesis dengan judul “**Metode Hybrid ARIMAX-QR dan QRNN untuk Peramalan *Inflow* dan *Outflow* Uang Kartal BI (Studi Kasus: BI Provinsi NTT dan Nasional)**”. Tesis ini merupakan salah satu syarat kelulusan dalam pelaksanaan tugas akhir program pascasarjana strata-2 (S2) di Program Magister Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Institut Teknologi Sepuluh Nopember (ITS) Surabaya.

Dalam penulisan karya ilmiah ini penulis mendapatkan banyak pengetahuan, inspirasi, saran dan pelajaran berharga sehingga penulis menyampaikan terima kasih kepada:

1. Bapak Gole, Ibu Hermina, Kakak Antonius, Monika, Neldis dan seluruh keluarga yang selalu memberikan motivasi, doa tulus, serta bantuan baik moril maupun materi, sehingga penulis dapat menyelesaikan tesis ini tepat pada waktunya.
2. Lembaga Pengelola Dana Pendidikan (LPDP) atas dukungan dana bagi penulis dalam menyelesaikan pendidikan di Institut Teknologi Sepuluh November.
3. Bapak Dr. Suhartono, M.Sc selaku Ketua Jurusan Statistika FMIPA ITS sekaligus pembimbing dan Bapak Dr. rer.pol. Dedy Dwi Prastyo, M.Si selaku co-pembimbing yang tidak kenal lelah meluruskan apa yang benar serta tidak hentinya dengan sabar memberikan arahan, bimbingan, pengetahuan, demi terselesainya tesis ini.
4. Bapak Dr. R. Mohamad Atok, M.Si dan Bapak Dr. Agus Suharsono, MS sebagai tim dosen penguji yang telah berkenan untuk menguji dan memberikan banyak ilmu pengetahuan, saran dan koreksi dalam proses penulisan tesis ini.
5. Dr. rer.pol. Heri Kuswanto, M.Si. selaku Ketua Program Pascasarjana S2 Statistika FMIPA ITS.
6. Bapak Dr. Muhammad Mashuri, MT. selaku dosen wali, yang menjadi pengganti orang tua yang baik selama penulis menjalani perkuliahan. Terima kasih atas bimbingan dan nasihat yang telah diberikan selama ini.
7. Seluruh tim dosen dan staff di Program Magister Jurusan Statistika FMIPA ITS Surabaya yang telah memberikan pengajaran, ilmu pengetahuan dan kelancaran administrasi selama penulis menjalani perkuliahan di Program Studi Statistika.
8. Institut Keguruan dan Teknologi Larantuka yang telah memberikan kesempatan bagi penulis untuk melanjutkan studi serta tak lupa pula ikut memberikan dukungan



moril serta materi bagi penulis dalam menjalani perkuliahan di Program Studi Statistika.

9. Temen-temen LPDP PP Afirmasi ITS 2015 yang telah banyak memberikan dukungan, motivasi, perhatian dan semangat bagi penulis untuk menyelesaikan studi di Program Magister Jurusan Statistika FMIPA ITS Surabaya.
10. Adik Alvionita, Amanda, Nisa, mbak Riza, dan teman-teman angkatan 2015 lainnya sebagai teman seperjuangan yang telah bersama-sama melewati setiap tahapan kuliah hingga tesis, *sharing* ilmu dan keluh kesah selama menjalani perkuliahan di Program Magister Jurusan Statistika FMIPA ITS. Terimakasih telah menjadi bagian selama masa perkuliahan di Program Magister Jurusan Statistika FMIPA ITS Surabaya.
11. Terima kasih kepada pihak-pihak lain yang tidak dapat disebutkan satu per satu yang telah membantu penulis dalam menyelesaikan Tesis ini.

Penulis menyadari masih banyak kekurangan dalam penyusunan tesis ini. Untuk itu penulis mengharapkan kritik dan saran yang membangun. Akhir kata, penulis berharap semoga tesis ini dapat memberikan manfaat kepada berbagai pihak sebagaimana tujuan penulis.

Surabaya, Juli 2017

Penulis,

Agnes Ona Bliti Puka

## DAFTAR ISI

	Halaman
<b>LEMBARAN PENGESAHAN .....</b>	iii
<b>ABSTRAK .....</b>	v
<b>ABSTRACT .....</b>	vii
<b>KATA PENGANTAR .....</b>	ix
<b>DAFTAR ISI.....</b>	xi
<b>DAFTAR TABEL .....</b>	xiii
<b>DAFTAR GAMBAR .....</b>	xvii
<b>DAFTAR LAMPIRAN .....</b>	xix
 <b>BAB 1 PENDAHULUAN .....</b>	 1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	6
1.3 Tujuan Penelitian .....	6
1.4 Manfaat Penelitian .....	7
1.5 Batasan Penelitian.....	8
 <b>BAB 2 TINJAUAN PUSTAKA .....</b>	 9
2.1 <i>Time Series Regression</i> .....	9
2.2 <i>Autoregressive Integrated Moving average (ARIMA)</i> .....	10
2.3 Model ARIMAX .....	13
2.4 Metode <i>Neural Network</i> .....	14
2.5 <i>Quantile Regression (QR)</i> .....	22
2.6 Model <i>Hybrid QRNN</i> .....	24
2.7 Bank Indonesia .....	25
 <b>BAB 3 METODE PENELITIAN .....</b>	 27
3.1 Data dan Variabel Penelitian .....	27
3.2 Langkah Analisis .....	29
3.2.1 Meramalkan Data dengan Menggunakan Model <i>Hybrid</i> ARIMAX-QR .....	29
3.2.2 Meramalkan Data Menggunakan Model <i>Hybrid QRNN</i> ..	30
3.2.3 Pemilihan Model Terbaik .....	31
 <b>BAB 4 HASIL DAN PEMBAHASAN .....</b>	 33

4.1 Studi Simulasi .....	33
4.1.1 Simulasi Data Bangkitan .....	33
4.1.2 Hasil Simulasi.....	39
4.2 Karakteristik Inflow dan Outflow uang Kartal .....	62
4.3 Model <i>Hybrid</i> ARIMAX-QR untuk <i>Inflow</i> dan <i>Outflow</i> Uang Kartal Provinsi NTT dan Nasional .....	68
4.3.1 Model <i>Hybrid</i> ARIMAX-QR untuk <i>Inflow</i> Uang Kartal BI Provinsi NTT.....	69
4.3.2 Model <i>Hybrid</i> ARIMAX-QR untuk <i>Outflow</i> Uang Kartal BI Provinsi NTT .....	76
4.3.3 Model <i>Hybrid</i> ARIMAX-QR untuk <i>Inflow</i> Uang Kartal BI Nasional.....	83
4.3.4 Model <i>Hybrid</i> ARIMAX-QR untuk <i>Outflow</i> Uang Kartal Nasional.....	91
4.4 Model <i>Hybrid</i> QRNN <i>Inflow</i> dan <i>Outflow</i> Uang Kartal Provinsi NTT dan Nasional.....	98
4.4.1 Model <i>Hybrid</i> QRNN untuk <i>Inflow</i> Uang Kartal Provinsi NTT .....	98
4.4.2 Model <i>Hybrid</i> QRNN untuk <i>Outflow</i> Uang Kartal Provinsi NTT .....	101
4.4.3 Model <i>Hybrid</i> QRNN untuk <i>Inflow</i> Uang Kartal Provinsi Nasional .....	105
4.4.4 Model <i>Hybrid</i> QRNN untuk <i>Inflow</i> Uang Kartal Provinsi Nasional .....	108
4.5 Pemilihan Model Terbaik .....	113
<b>BAB 5 KESIMPULAN DAN SARAN .....</b>	<b>117</b>
5.1 Kesimpulan .....	117
5.2 Saran .....	117
<b>DAFTAR PUSTAKA</b>	
<b>LAMPIRAN</b>	

## DAFTAR TABEL

	Halaman
Tabel 2.1 Karakteristik ACF dan PACF Teoritis Proses Non-musiman .....	11
Tabel 2.2 Karakteristik ACF dan PACF Teoritis Proses Musiman .....	12
Tabel 3.1 Notasi dan Variabel Penelitian .....	27
Tabel 3.2 Terjadinya Idulfitri.....	28
Tabel 3.3 Struktur Data Penelitian .....	29
Tabel 4.1 Rentang Nilai untuk Pola Musiman yang Bersifat Heterogen.....	38
Tabel 4.2 Estimasi Parameter Regresi <i>Time Series</i> Skenario 1 .....	40
Tabel 4.3 Hasil Uji White Noise dan Normalitas pada Residual.....	41
Tabel 4.4 Estimasi Parameter dan Uji Signifikansi Parameter Skenario 1 .....	41
Tabel 4.5 Hasil Uji White Noise dan Normalitas pada Residual ARIMA .....	42
Tabel 4.6 Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 1.....	43
Tabel 4.7 Hasil Estimasi Parameter dan Uji signifikansi Parameter .....	44
Tabel 4.8 Nilai RMSE untuk Pemodelan ARIMAX-QR pada Skenario 1 .....	44
Tabel 4.9 Nilai RMSE untuk Pemodelan QRNN pada Skenario 1.....	45
Tabel 4.10 Nilai RMSE Replikasi Pemodelan <i>Hybrid</i> QRNN Skenario 1 .....	46
Tabel 4.11 Perbandingan RMSE untuk Skenario 1 .....	47
Tabel 4.12 Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 2.....	48
Tabel 4.13 Estimasi Parameter dan Uji signifikansi Parameter Model ARIMAX-QR Skenario 2 .....	49
Tabel 4.14 Nilai RMSE untuk Pemodelan ARIMAX-QR pada Skenario 2....	49
Tabel 4.15 Nilai RMSE untuk Pemodelan QRNN pada Skenario 2.....	50
Tabel 4.16 Nilai RMSE Replikasi Pemodelan <i>Hybrid</i> QRNN Skenario 2.....	51
Tabel 4.17 Perbandingan RMSE untuk Skenario 2 .....	52
Tabel 4.18 Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 3.....	53
Tabel 4.19 Estimasi Parameter dan Uji Signifikansi Parameter Skenario 3....	54
Tabel 4.20 Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 3.....	54
Tabel 4.21 Nilai RMSE untuk Pemodelan QRNN pada Skenario 3.....	55
Tabel 4.22 Nilai RMSE Replikasi Pemodelan QRNN pada Skenario 3.....	56
Tabel 4.23 Perbandingan RMSE untuk Skenario 3 .....	57
Tabel 4.24 Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 4.....	58
Tabel 4.25 Hasil Estimasi Parameter dan Uji signifikansi Parameter .....	59

Tabel 4.26 Nilai RMSE untuk Pemodelan ARIMAX-QR pada Skenario 4.....	59
Tabel 4.27 Nilai RMSE untuk Pemodelan QRNN pada Skenario 4.....	60
Tabel 4.28 Nilai RMSE Replikasi Pemodelan QRNN pada Skenario 4.....	61
Tabel 4.29 Perbandingan RMSE untuk Skenario 4 .....	62
Tabel 4.30 Karakteristik <i>Inflow</i> dan <i>Outflow</i> Nasional dan NTT .....	68
Tabel 4.31 Hasil Uji Asumsi <i>White Noise</i> ARIMAX <i>Inflow</i> NTT .....	69
Tabel 4.32 Hasil Pengujian Signifikansi Parameter ARIMA .....	70
Tabel 4.33 Hasil uji asumsi Independen residual ARIMA .....	71
Tabel 4.34 Estimasi Parameter Model ARIMAX(1,0,0)(1,0,0) <sup>12</sup> .....	72
Tabel 4.35 Akurasi Peramalan Menggunakan Model ARIMAX .....	73
Tabel 4.36 Uji Heterokedastisitas Mode ARIMAX .....	73
Tabel 4.37 Hasil Estimasi Parameter Model <i>hybrid</i> ARIMAX-QR .....	74
Tabel 4.38 Peramalan Menggunakan Model ARIMAX-QR untuk <i>Inflow</i> Uang Kartal BI Provinsi NTT .....	75
Tabel 4.39 Akurasi Peramalan Menggunakan Model ARIMAX-QR .....	76
Tabel 4.40 Hasil Uji Asumsi Independen Residual Regresi <i>Time series</i> <i>Outflow</i> NTT .....	77
Tabel 4.41 Hasil Pengujian Signifikansi Parameter .....	78
Tabel 4.42 Hasil Uji Asumsi Independen Residua ARIMA .....	79
Tabel 4.43 Akurasi Peramalan Menggunakan Model ARIMAX .....	80
Tabel 4.44 Uji Heteroskedastisitas Model ARIMAX .....	81
Tabel 4.45 Estimasi Parameter Model <i>hybrid</i> ARIMAX-QR .....	81
Tabel 4.46 Peramalan Menggunakan Model ARIMAX-QR .....	82
Tabel 4.47 Akurasi Peramalan Menggunakan Model ARIMAX-QR .....	83
Tabel 4.48 Hasil uji asumsi Independen residual Regresi <i>Time series</i> <i>Inflow</i> Nasional .....	84
Tabel 4.49 Hasil Pengujian Signifikansi Parameter <i>Inflow</i> Nasional .....	85
Tabel 4.50 Hasil uji asumsi Independen residual ARIMA .....	85
Tabel 4.51 Hasil Estimasi Parameter Model ARIMAX .....	87
Tabel 4.52 Akurasi Peramalan Menggunakan Model ARIMAX .....	88
Tabel 4.53 Uji Heteroskedastisitas Model ARIMAX Data <i>Inflow</i> Nasional...	88
Tabel 4.54 Hasil Estimasi Parameter Model <i>hybrid</i> ARIMAX-QR <i>Inflow</i> Uang Kartal BI Nasional .....	89
Tabel 4.55 Peramalan Model ARIMAX-QR <i>Inflow</i> Nasional .....	90

Tabel 4.56 Akurasi Peramalan Model ARIMAX-QR untuk <i>Inflow</i> .....	90
Tabel 4.57 Uji Asumsi Independen Residual Regresi <i>Time series Outflow</i> ...	92
Tabel 4.58 Hasil Pengujian Signifikansi Parameter .....	93
Tabel 4.59 Akurasi Peramalan Model ARIMAX <i>Outflow</i> Nasional .....	94
Tabel 4.60 Uji Heteroskedastisitas Model ARIMAX Data <i>Outflow</i> Nasional	95
Tabel 4.61 Estimasi Parameter Model <i>hybrid</i> ARIMAX-QR <i>Outflow</i> .....	95
Tabel 4.62 Peramalan Model ARIMAX-QR untuk <i>Outflow</i> Nasional .....	96
Tabel 4.63 Akurasi Peramalan Menggunakan Model ARIMAX-QR untuk <i>Outflow</i> Uang Kartal BI Provinsi NTT .....	97
Tabel 4.64 Perbandingan Akurasi Peramalan Menggunakan QRNN.....	99
Tabel 4.65 Peramalan Model <i>hybrid</i> QRNN untuk <i>Inflow</i> NTT .....	100
Tabel 4.66 Akurasi Peramalan Menggunakan Model <i>Hybrid</i> QRNN untuk <i>Inflow</i> Uang Kartal BI Provinsi NTT.....	101
Tabel 4.67 Perbandingan Akurasi Peramalan Menggunakan QRNN.....	102
Tabel 4.68 Peramalan Model <i>hybrid</i> QRNN untuk <i>Outflow</i> NTT.....	104
Tabel 4.69 Akurasi Peramalan Model <i>Hybrid</i> QRNN untuk <i>Outflow</i> NTT .....	104
Tabel 4.70 Perbandingan Akurasi Peramalan Menggunakan QRNN.....	106
Tabel 4.71 Peramalan Model <i>hybrid</i> QRNN untuk <i>Inflow</i> Nasional .....	108
Tabel 4.72 Akurasi Peramalan Model <i>Hybrid</i> QRNN untuk <i>Inflow</i> Nasional .	108
Tabel 4.73 Perbandingan Akurasi Peramalan Menggunakan QRNN.....	110
Tabel 4.74 Peramalan Model <i>hybrid</i> QRNN untuk <i>Outflow</i> NTT.....	112
Tabel 4.75 Akurasi Peramalan Model <i>Hybrid</i> QRNN untuk <i>Outflow</i> NTT .....	112
Tabel 4.76 Perbandingan RMSE dan MdAE <i>In-sample</i> Tiap Metode .....	114
Tabel 4.77 Perbandingan RMSE dan MdAE <i>Out-Sample</i> Tiap Metode .....	115

*“Halaman ini sengaja dikosongkan”*

## DAFTAR GAMBAR

	Halaman
Gambar 2.1 Arsitektur Model NN .....	15
Gambar 2.2 Fungsi <i>Threshold</i> .....	16
Gambar 2.3 Fungsi Linear <i>Piecewise</i> .....	16
Gambar 2.4 Fungsi Sigmoid .....	17
Gambar 2.5 Fungsi Tangen Hiperbolik .....	17
Gambar 2.6 Fungsi Gaussian .....	17
Gambar 2.7 Simple Linear Perceptron.....	18
Gambar 2.8 Simple Nonlinear Perceptronp .....	19
Gambar 2.9 Bentuk Transformasi dari Multilayer Perceptron .....	19
Gambar 2.10 <i>Loss Function</i> .....	23
Gambar 3.1 Diagram Alir Analisis Model <i>Hybrid</i> ARIMAX-QR QRNN.....	32
Gambar 4.1 Plot untuk Komponen Tren (a), Pola Musiman Homogen (b), Pola Musiman Heterogen (c), Efek Variasi Kalender (d) .....	34
Gambar 4.2 Komponen Residual Mengikuti Pola Linear (a) Nonlinear (b) ...	35
Gambar 4.3 Plot Residual dari Proses Regresi <i>Time Series</i> yang Mengikuti Model Linear dengan Lag 1(a) dan Nonlinear (b) .....	35
Gambar 4.4 Plot <i>Time Series</i> pada Skenario 1 (a) dan Boxplot (b) .....	36
Gambar 4.5 Plot <i>Time Series</i> pada Skenario 2 (a) dan Boxplot (b) .....	37
Gambar 4.6 Plot <i>Time Series</i> pada Skenario 3 (a) dan Boxplot (b).....	38
Gambar 4.7 Plot <i>Time Series</i> pada Skenario 4 (a) dan Boxplot (b).....	39
Gambar 4.8 <i>Time series</i> Plot <i>Inflow-Outflow</i> Uang Kartal Provinsi NTT(a,b) dan Nasional(c,d) .....	63
Gambar 4.9 Boxplot <i>Inflow</i> dan <i>Outflow</i> Uang Kartal BI .....	65
Gambar 4.10 Plot ACF dan PACF dari Residual Regresi <i>Time series</i> <i>Inflow</i> Uang Kartal BI NTT .....	70
Gambar 4.11 Ramalan <i>Out-sample</i> Model <i>Hybrid</i> ARIMAX-QR .....	76
Gambar 4.12 Plot ACF dan PACF dari Residual Regresi <i>Time Series</i> <i>Outflow</i> Uang Kartal BI NTT .....	78
Gambar 4.13 Ramalan <i>Out-sample</i> ARIMAX-QR <i>Outflow</i> BI NTT .....	83
Gambar 4.14 Plot ACF dan PACF dari Residual Regresi <i>Time Series</i> <i>Inflow</i> Uang Kartal BI Nasional .....	85



Gambar 4.15 Ramalan Interval <i>Out-sample Inflow</i> Uang Kartal ARIMAX-QR BI Nasional .....	91
Gambar 4.16 Plot ACF dan PACF Residual Regresi <i>Time Series outflow</i> .....	92
Gambar 4.17 Ramalan <i>Out-sample</i> ARIMAX-QR <i>Outflow</i> Nasional.....	97
Gambar 4.18 <i>Architecture</i> Model <i>hybrid</i> QRNN dengan 1 Input dan 1 <i>hidden neuron Inflow</i> NTT .....	100
Gambar 4.19 Ramalan Interval <i>Out-sample</i> QRNN <i>Inflow</i> NTT .....	101
Gambar 4.20 <i>Architecture</i> model <i>hybrid</i> QRNN untuk <i>Outflow</i> NTT .....	103
Gambar 4.21 Ramalan Interval <i>Out-sample</i> QRNN <i>Outflow</i> NTT .....	105
Gambar 4.22 <i>Architecture</i> model <i>hybrid</i> QRNN untuk <i>Inflow</i> Nasional .....	107
Gambar 4.23 Ramalan Interval <i>Out-sample</i> ARIMAX-QR <i>Inflow</i> Nasional..	109
Gambar 4.24 <i>Architecture</i> model <i>hybrid</i> QRNN untuk <i>Outflow</i> Nasional.....	111
Gambar 4.25 Ramalan Interval <i>Out-sample</i> QRNN <i>Outflow</i> .....	113
Gambar 4.26 RMSE Aditif $k$ Langkah Kedepan .....	116
Gambar 4.27 Perbandingan Ramalan tiap Metode .....	116

## DAFTAR LAMPIRAN

	Halaman
Lampiran 1. Data Simulasi .....	119
Lampiran 2. Data <i>Inflow</i> dan <i>Outflow</i> Uang Kartal BI.....	125
Lampiran 3. Uji Heteroskedastisitas dan Nonlinearitas data.....	129
Lampiran 4. Syntax Prorgam SAS 9.1.....	131
Lampiran 5. Output SAS Model ARIMAX.....	132

*“Halaman ini sengaja dikosongkan”*

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Pemodelan nonlinear, nonparametrik dan heteroskedastisitas mengalami perkembangan yang pesat pada beberapa dekade terakhir ini seiring dengan perkembangan komputer dan kemampuan komputasi. Pemodelan nonlinear sering digunakan untuk menjelaskan hubungan nonlinear antar variabel yang diyakini mampu memprediksi kenyataan dengan tingkat akurasi yang tinggi dibandingkan dengan pendekatan linear. Kompleksitas model yang melibatkan tak terhingga banyaknya parameter pada pemodelan nonlinear dapat diatasi dengan menggunakan pendekatan nonparametrik. Pendekatan nonparametrik tidak memerlukan asumsi bentuk hubungan fungsional antar variabel. Pendekatan nonparametrik bertujuan untuk mengurangi bias yang mungkin terjadi pada model parametrik. Salah satu kontribusi penting dari pemodelan statistik bagi perkembangan ilmu pengetahuan dan teknologi dewasa ini khususnya dalam bidang ekonometrika yakni mampu meramalkan kejadian yang akan datang dengan menggunakan data masa lalu. Untuk melakukan peramalan ini dibutuhkan asumsi penting dalam model regresi yakni varians residual yang homogen (homoskedastisitas). Apabila varians dari residual tidak homogen atau tidak identik maka disebut dengan heteroskedastisitas.

Peramalan *time series* merupakan salah satu bidang peramalan yang menganalisis fenomena historikal untuk mendapatkan sebuah model yang dapat menjelaskan hubungan antara variabel-variabel yang mendasarinya. Data *time series* terdiri dari struktur korelasi linear dan nonlinear (Zhang, 2003). Dalam penelitian tersebut, korelasi linear antar variabel dapat diatasi dengan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA). Meskipun metode ARIMA cukup fleksibel namun keterbatasan utama adalah dengan mengasumsikan pola model tersebut linear sehingga tidak ada pola nonlinear yang bisa ditangkap dengan model ARIMA.

Liu (1986) telah melakukan penelitian tentang variasi kalender. Dalam penelitian tersebut ARIMA dimodifikasi dengan memasukkan informasi liburan sebagai *input* deterministik. Lee, Suhartono dan Hamzah (2010) memperkenalkan pengembangan *time series* regresi dengan model variasi kalender untuk penjualan produk busana muslim. Selain itu, Suhartono dan Lee (2011) mengembangkan model variasi kalender untuk penjualan bulanan dari produk garmen di perusahaan ritel. Model-model ARIMA yang dimodifikasi tersebut disebut ARIMAX. Model ARIMAX hanya dapat menangkap korelasi linear, sehingga komponen nonlinear akan tetap berada di residual.

*Neural Network* (NN) adalah model yang mampu mendekati berbagai variasi data nonlinear dengan waktu penyelesaian yang cepat dan robust terhadap *missing data*. NN merupakan gambaran dari cara kerja otak manusia dalam hal mengingat, menghitung dan menggeneralisasi. NN berusaha meniru struktur/arsitektur dan cara kerja otak manusia terutama dalam hal mengenali pola, prediksi, klasifikasi, pendekatan fungsi dan optimisasi. Terdapat banyak perkembangan riset yang membahas tentang NN seperti McCulloch dan Pitt pada tahun 1940-an, Rosenblatt yang menemukan teknik perceptron pada tahun 1960-an dan disusul Minsky dan Papert yang membuktikan kelemahan teknik perceptron yang ditemukan Rosenblatt. Kelebihan utama dari model NN adalah kemampuan utama untuk memprediksi, mempunyai toleransi yang tinggi terhadap data yang mengandung noise serta mampu menangkap hubungan yang sangat kompleks antara variabel prediktor dan outputnya. Sedangkan kekurangan dari NN adalah tidak adanya model struktural yang jelas karena bersifat menyelesaikan permasalahan *black-box*. Selain itu dalam hal ekstrapolasi, walaupun mampu menggeneralisasi data insample, NN bisa menghasilkan prediksi yang invalid bila harus menerima input diluar range yang diberikan saat training.

Model linear memiliki keuntungan yakni kemudahan interpretasi sedangkan model nonlinear dikenal memiliki akurasi yang tinggi. Untuk itu dibutuhkan suatu metode yang dapat menggabungkan keunggulan dari model linear dan nonlinear. Salah satu model yang dapat digunakan adalah model *hybrid*. Pemodelan *hybrid* dapat meminimalisir *error* dan memberikan tingkat akurasi yang tinggi (Zhang, 2003). Metode *hybrid* telah diperkenalkan oleh

Zhang (2003) dengan menggunakan ARIMA untuk model komponen linear dan menggunakan NN untuk model komponen nonlinear. Untuk pengembangan model yang presisi dan lebih akurat dibutuhkan model *hybrid* lain sebagai pembandingan. Dalam peramalan *time series*, perkiraan dasar dapat berasal dari model apapun. Namun, untuk mendapatkan hasil terbaik dibutuhkan model yang sesuai.

Dalam peramalan *time series* terdapat dua jenis peramalan yakni peramalan titik dan peramalan interval. Peramalan interval terinspirasi dari pernyataan Gardner (1988, hal. 541-546) dimana terdapat banyak kesalahan dalam peramalan titik. Peramalan titik seringkali memberikan hasil yang kurang memuaskan dalam pengambilan keputusan ketika berada pada situasi yang ekstrem dan tidak menentu (Li *et al.*, 2012). Chatfield (2000) menyebutkan bahwa peramalan interval sangat penting dalam menilai ketidakpastian masa depan, merencanakan strategi yang berbeda untuk berbagai hasil yang mungkin, perbandingan peramalan dan menjelajahi skenario yang berbeda berdasarkan asumsi yang berbeda. Dalam peramalan *inflow* dan *outflow* uang kartal, estimasi peramalan interval sangat dibutuhkan dalam penilaian dan perencanaan serta pembuatan kebijakan. Untuk mengatasi masalah ini, peramalan titik dikonversi ke peramalan interval.

Peramalan interval pada data *time series* memerlukan asumsi varians residual yang konstan dari waktu ke waktu, namun dalam bidang keuangan sering ditemui data *time series* dengan varians residual yang tidak konstan dari waktu ke waktu yang dinamakan heterokedastisitas. Keberadaan heteroskedastisitas merupakan perhatian utama dalam penerapan analisis regresi termasuk analisis varians, karena pengujian parameter dengan statistik uji t menjadi tidak valid dan cenderung untuk menolak hipotesis. Selain itu, perkiraan selang untuk parameter regresi cenderung melebar. Konsekuensi dari adanya heteroskedastisitas ini adalah estimasi OLS menjadi tidak bias dan konsisten namun tidak efisien. Oleh karena itu Taylor dan Bunn (1999) menggunakan *Quantiles Regression* (QR) pada residual untuk peramalan interval.

Kuantil adalah suatu teknik pembagian sekelompok data kepada beberapa bagian yang sama, setelah data diurutkan dari yang paling kecil atau paling besar.

Metode QR merupakan suatu pendekatan dalam analisis regresi yang dikenalkan oleh Koenker dan Bassett (1978). Analisis metode regresi ini dilakukan dengan pembagian atau pemisahan data menjadi beberapa kelompok yang dicurigai mempunyai perbedaan nilai dugaan pada kuantil-kuantil tersebut. Pendekatan ini menduga berbagai fungsi kuantil dari suatu distribusi Y dengan syarat X. Distribusi kuantil bersyarat dari variabel respon dinyatakan sebagai fungsi dari kovariat yang diamati. Koenker dan Hallock (2005) menyatakan bahwa QR berguna untuk data yang memiliki pola sebaran bersyarat yang tidak simetris, data yang memiliki sebaran padat di bagian ekor (atas atau bawah) dan sebaran yang terpotong. Selain itu, QR juga bermanfaat digunakan ketika ingin mengetahui tingkat perubahan pada kuantil bersyarat yang dinyatakan oleh koefisien regresi pada kuantil tertentu. Untuk mendapatkan estimasi parameter model regresi kuantil yaitu dengan metode pemrograman linier diantaranya metode *simpleks*, *interior-point*, dan *smoothing*. Secara umum, QR sangat bermanfaat ketika ingin menganalisis bagian tertentu dari suatu sebaran bersyarat.

Beberapa penelitian selanjutnya mencoba mengembangkan metode regresi kuantil dalam peramalan *hybrid*. Taylor (2000) mengaplikasikan pendekatan baru dalam mengestimasi distribusi peluang bersyarat dari data saham. Penelitian tersebut menggunakan pendekatan regresi kuantil untuk mengatasi kebutuhan akan asumsi distribusi dan menggunakan *neural network* untuk mengestimasi kekuatan model nonlinear kuantil. Cannon (2011) mengembangkan penelitian yang sama yakni *hybrid Quantile Regression Neural Network* (QRNN) dengan menggunakan software R dan mengaplikasikannya untuk peramalan curah hujan. Hasil penelitian menunjukkan bahwa *hybrid QRNN* dapat meningkatkan akurasi peramalan. Arunraj dan Ahrens (2015) menggunakan *Hybrid SARIMAX* dan *Quantile Regression* (QR) untuk peramalan penjualan makanan harian. Setelah melakukan perbandingan dengan beberapa metode peramalan seperti *naive forecasting*, *traditional SARIMA* dan *Multilayer Perceptron Neural Network* (MLPNN), dikatakan bahwa metode *hybrid SARIMAX-QR* memberikan akurasi peramalan interval lebih baik dibandingkan dengan metode lainnya.

Indonesia merupakan salah satu dari sekian banyak negara berkembang. Dalam proses perkembangannya, perekonomian memegang peranan penting.

Sejarah perkembangan peradaban manusia menunjukkan bahwa uang memiliki peranan strategis dalam perekonomian terutama karena fungsi utamanya sebagai alat pembayaran. Sampai saat ini pun sebagian besar transaksi ekonomi masih menggunakan mata uang sebagai alat pembayaran. Di Indonesia, kebijakan pengedaran uang dilakukan oleh Bank Indonesia yang kewenangannya diatur dalam Undang-Undang nomor 23 tahun 1999 tentang Bank Indonesia.

Untuk mengelola stok mata uang di masa depan, dibutuhkan perkiraan yang akurat tentang penyetoran uang (*inflow*) dan penarikan uang (*outflow*). Untuk itu perlu adanya kajian tentang *inflow* dan *outflow* yang berkontribusi bagi Bank Indonesia dalam penetapan kebijakan-kebijakannya. Fenomena *inflow* dan *outflow* di Indonesia sangat erat kaitannya dengan pengaruh waktu, data historis terjadinya *inflow* dan *outflow* sangat membantu dalam peramalan *inflow* dan *outflow* uang kartal yang beredar di Indonesia. Metode peramalan yang mampu menangkap fenomena data historis dengan lebih akurat menjadi kebutuhan dalam mengembangkan model yang presisi. Ada beberapa studi sebelumnya yang meneliti tentang *inflow* mata uang dan peramalan *outflow*, antara lain Ahmad *et al.*, (2015), Setiawan *et al.*, (2015), serta Reganata dan Suhartono (2016). Penelitian yang dilakukan menganalisis data individual untuk beberapa kantor cabang dengan menggunakan metode regresi *time series* dan ARIMAX.

Dalam kasus *inflow* dan *outflow* di Bank Indonesia, faktor sosial budaya daerah secara lokal seperti perayaan Idul Fitri, perayaan Imlek, hari raya Nyepi dan sebagainya berpengaruh penting dalam penyusunan model. Mengingat Indonesia adalah negara dengan mayoritas muslim menyebabkan banyak data ekonomi memiliki pola musiman yang dipengaruhi oleh dua jenis kalender, yaitu kalender Kristen dan kalender Islam. Efek kalender Kristen menyebabkan *inflow* dan *outflow* tinggi atau rendah pada bulan tertentu, sedangkan kalender Islam mempengaruhi arus masuk dan keluar di bulan sekitar liburan Idul Fitri. Efek ini disebut efek liburan (Liu, 1986; Sullivan, Timmermann dan White, 2001; Sayyid, Abraham dan Al-Hajji, 2005; Alagidede, 2008; Lee, Suhartono dan Hamzah, 2010; Suhartono dan Lee, 2011). Efek liburan ini tidak dapat diidentifikasi sebagai efek musiman karena hari libur Idul Fitri terjadi pada berbagai tanggal dan bulan dalam kalender Kristen dari tahun ke tahun.



Pada data bulanan, efek Idul Fitri bervariasi tergantung pada tanggal Idul Fitri terjadi. Untuk menangkap efek ini, diperlukan variabel *dummy* yang mewakili masing-masing hari terjadi Idul Fitri. Variabel *dummy* yang digunakan merupakan *dummy* mingguan, dimana terdapat 4 minggu dalam satu bulan. Selain menggunakan *dummy* minggu, digunakan pula *dummy* efek satu minggu sebelum dan sesudah Idul Fitri. Hal ini didukung oleh banyak penelitian sebelumnya yang menyatakan bahwa satu minggu sebelum dan sesudah terjadinya Idul Fitri berpengaruh terhadap peningkatan *inflow* dan *outflow* uang kartal BI baik di tingkat Provinsi NTT maupun di tingkat Nasional.

Berdasarkan penjelasan di atas, penelitian ini menggunakan peramalan data *inflow* dan *outflow* mata uang bulanan di Bank Indonesia dengan menggunakan metode *hybrid* ARIMAX-QR dan QRNN. Kedua metode ini digunakan untuk menanggulangi masalah nonlinearitas dan heteroskedastisitas pada pola data *inflow* dan *outflow* uang kartal di Bank Indonesia. Kriteria *Root Mean Squared Error* (RMSE) dan Median Absolut Error (mdAE) digunakan untuk membandingkan seberapa besar tingkat akurasi kedua model tersebut. Kedua kriteria ini bergantung pada skala data dan sangat baik digunakan ketika ingin membandingkan metode yang berbeda yang diterapkan pada data yang sama (Hyndman, 2006)

## 1.2 Rumusan Masalah Penelitian

Pada peramalan yang melibatkan data *time series*, telah dikembangkan banyak metode peramalan dengan berbagai tingkat akurasi yang mencerminkan seberapa tepat suatu metode yang ditawarkan mampu memprediksi kenyataan. Dalam menjalankan tugas dan fungsinya, Bank Indonesia memerlukan adanya perkiraan yang akurat dalam mengeluarkan dan mengedarkan uang. Oleh karena itu perlu adanya pengembangan metode baru dalam peramalan *inflow* dan *outflow* uang kartal di Bank Indonesia. Sesuai dengan apa yang telah dipaparkan pada latar belakang, permasalahan yang dikaji dalam penelitian ini adalah:

1. Bagaimana model peramalan *hybrid* ARIMAX-QR untuk data *inflow* dan *outflow* di Bank Indonesia Provinsi Nusa Tenggara Timur (NTT) dan Nasional?

2. Bagaimana model peramalan *hybrid* QRNN untuk data *inflow* dan *outflow* di Bank Indonesia Provinsi NTT dan Nasional?
3. Bagaimana peramalan interval dengan menggunakan model *hybrid* QRNN untuk data *inflow* dan *outflow* di Bank Indonesia area NTT dan Nasional?
4. Bagaimana tingkat akurasi ramalan model *hybrid* pada data *in sample* dan *out sample* yang berkaitan dengan data *inflow* dan *outflow* uang kartal di Bank Indonesia Provinsi NTT dan Nasional?

### 1.3 Tujuan penelitian

Berdasarkan rumusan masalah yang telah dipaparkan, diharapkan penelitian ini mampu menjawab tujuan berikut ini.

1. Memodelkan data *inflow* dan *outflow* dengan menggunakan metode *hybrid* ARIMAX-QR untuk data *inflow* dan *outflow* di Bank Indonesia Provinsi NTT dan Nasional.
2. Memodelkan data *inflow* dan *outflow* dengan menggunakan model *hybrid* QRNN untuk data *inflow* dan *outflow* di Bank Indonesia Provinsi NTT dan Nasional.
3. Melakukan peramalan interval dengan menggunakan model *hybrid* QRNN untuk data *inflow* dan *outflow* di Bank Indonesia provinsi NTT dan Nasional?
4. Mengkaji perbandingan tingkat akurasi model *hybrid* pada data *in sample* dan *out sample* yang berkaitan dengan data *inflow* dan *outflow* uang kartal di Bank Indonesia Provinsi NTT dan Nasional.

### 1.4 Manfaat penelitian

Penelitian ini diharapkan dapat berkontribusi bagi berbagai pihak khususnya Bank Indonesia dalam menangani masalah keakuratan ramalan data *inflow* dan *outflow* dengan metode *hybrid* ARIMAX-QR dan *hybrid* QRNN. Dengan demikian informasi yang diperoleh dari hasil penelitian ini dapat dijadikan pertimbangan dalam penentuan kebijakan pengedaran uang. Bagi para akademisi, diharapkan penelitian ini mampu menambah wawasan pengetahuan tentang metode *hybrid* dalam mengatasi data yang mengandung *outlier* dan tidak terpenuhinya asumsi homokedastisitas.

### 1.5 Batasan masalah penelitian

Terdapat 46 kantor cabang Bank Indonesia yang tersebar di Indonesia yang terdiri dari 33 kantor perwakilan Bank Indonesia Provinsi, 12 kantor perwakilan Bank Indonesia Kota/Kabupaten dan 1 kantor pusat Bank Indonesia (Website BI). Data yang digunakan dalam penelitian ini dibatasi yakni data bulanan *inflow* dan *outflow* Bank Indonesia Provinsi NTT dan Nasional. Pertimbangan pemilihan Provinsi NTT sebagai sampel penelitian ini yakni dari plot data *inflow* dan *outflow* uang kartal di Provinsi NTT menunjukkan efek musiman dan variasi kalender akibat hari raya Idul Fitri meskipun diketahui bahwa Provinsi NTT merupakan salah satu provinsi di Indonesia dengan jumlah penduduk beragama Katolik sebesar 56,281%, Kristen Protestan sebesar 34,21%, Islam sebesar 9,283%, Hindu sebesar 0,233% dan Budha sebesar 0,003%, dimana persentase jumlah penduduk Islam lebih kecil dibanding provinsi lain di Indonesia. Perbedaan persentase jumlah penduduk ini menyebabkan adanya perbedaan nilai *inflow* dan *outflow* uang kartal di Provinsi NTT dengan provinsi lain di Indonesia yang memiliki jumlah penduduk Islam lebih besar. Untuk itu akan dikaji seberapa besar perbandingan nilai *inflow* dan *outflow* uang kartal di Provinsi NTT dengan nilai *inflow* dan *outflow* uang kartal Nasional. Ada banyak faktor yang diduga berpengaruh terhadap fluktuasi *inflow* dan *outflow* uang kartal di Bank Indonesia. Faktor-faktor tersebut antara lain perubahan kebijakan BI, efek variasi kalender yang disebabkan oleh hari raya Idul Fitri, hari raya Natal, Paskah dan Nyepi. Faktor-faktor yang digunakan sebagai variabel input dalam penelitian ini dibatasi yakni dengan menggunakan variabel efek variasi kalender pada hari raya Idul Fitri.

## BAB II

### TINJAUAN TEORI

Pada bab ini akan dijelaskan pustaka yang mendukung dalam menganalisis permasalahan penelitian yang berkaitan dengan regresi *time series* ARIMA, ARIMAX, NN, Regresi Kuantil dan Peramalan *Hybrid*.

#### 2.1 Regresi Time Series

Lingkaran kehidupan manusia tidak terlepas dari suatu deretan waktu yang saling berkaitan membentuk suatu pola. Pola dari data tersebut dapat berupa *trend*, musiman, *calender variation* dan kecenderungan mengikuti proses kenaikan atau penurunan sekular jangka panjang dalam data. Pola dari sederetan waktu ini mengundang banyak peneliti untuk mengkaji dan menggali lebih jauh informasi-informasi penting yang terkandung didalamnya. Model *time series* digunakan untuk meramalkan kondisi masa yang akan datang menggunakan data historis dan mengeksplorasi pola tersebut ke masa depan. Dalam regresi *time series* ada beberapa komponen yang berpengaruh penting yakni komponen *trend*, *cycle*, variasi musiman dan fluktuasi *irregular* (Bowerman dan O'Connell, 1993, hal 5-6). *Trend* mengacu pada gerakan ke atas dan kebawah dalam rangkaian peristiwa pada waktu  $t$ . *Cycle* mengacu pada gerakan berulang keatas dan kebawah disekitar level *trend*. Variasi musiman mengacu pada pola periodik dalam suatu kurun waktu yang terjadi dalam satu tahun dan diulang setiap tahun. *Irregular* mengacu pada gerakan tidak menentu dalam suatu kurun waktu. Ada 3 komponen utama yang sering digunakan dalam pemodelan regresi *time series* yakni seperti yang tertulis pada persamaan (2.1)

$$Y_t = T_t + S_t + v_t \quad (2.1)$$

dengan:

$Y_t$  = nilai observasi dari data *time series* pada periode ke- $t$

$T_t$  = *trend* pada periode ke- $t$

$S_t$  = faktor musiman pada periode ke- $t$

$v_t$  = error pada periode ke- $t$ .

Salah satu cara untuk memodelkan pola musiman yakni dengan menggunakan variabel *dummy*. Misalkan  $L$  adalah musim (bulan) setiap tahun, maka  $SN_t$  didefinisikan dalam persamaan (2.2)

$$S_t = S_{s1}x_{s1,t} + S_{s2}x_{s2,t} + \dots + S_{s(L-1)}x_{s(L-1),t} \quad (2.2)$$

dengan  $x_{s1,t}, x_{s2,t}, \dots, x_{s(L-1),t}$  adalah variabel *dummy* yang didefinisikan dalam persamaan (2.3)

$$\begin{aligned} x_{s1,t} &= \begin{cases} 1, & \text{jika waktu } t \text{ adalah musim 1} \\ 0, & \text{lainnya} \end{cases} \\ x_{s2,t} &= \begin{cases} 1, & \text{jika waktu } t \text{ adalah musim 2} \\ 0, & \text{lainnya} \end{cases} \\ &\vdots \\ x_{s(L-1),t} &= \begin{cases} 1, & \text{jika waktu } t \text{ adalah musim } L-1 \\ 0, & \text{lainnya.} \end{cases} \end{aligned} \quad (2.3)$$

Untuk data dengan efek variasi kalender, regresi *time series* dapat diaplikasikan dengan menambahkan variabel *dummy*.

## 2.2 Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA pertama kali diperkenalkan oleh George Box dan Gwilym Jenkins pada tahun 1976. Model ini merupakan gabungan antara proses *Autoregressive* (AR) dan *moving average* (MA). Model ini dapat diaplikasikan pada data musiman atau *non*-musiman dan data stasioner atau *non*-stasioner. Tidak terpenuhinya syarat kestasioneran menyebabkan terjadinya proses *differencing* atau *integrated* (I). Bentuk umum dari model ARIMA(p,d,q)(P,D,Q)<sup>L</sup> didefinisikan pada persamaan (2.4)

$$Y_t = \frac{\theta_q(B)\Theta_Q(B^L)}{w_p(B)\Phi_P(B^L)(1-B)^d(1-B^L)^D} a_t \quad (2.4)$$

dengan :

$w_p(B) = (1 - w_1B - w_2B^2 - \dots - w_pB^p)$  adalah koefisien komponen AR *non*-musiman dengan derajat  $p$ ,

$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$  adalah koefisien komponen MA *non*-musiman dengan derajat  $q$ ,

$\Phi_p(B^L) = (1 - \Phi_1 B^L - \Phi_2 B^{2L} - \dots - \Phi_p B^{pL})$  adalah koefisien komponen AR musiman dengan derajat  $P$ ,

$\Theta_Q(B) = (1 - \Theta_1 B^L - \Theta_2 B^{2L} - \dots - \Theta_Q B^{QL})$  adalah koefisien komponen MA musiman dengan derajat  $Q$ ,

$B$  adalah operator *backshift*,

$L$  adalah periode musiman,

$a_t$  adalah proses *white noise* dengan mean nol dan varians konstan,

$t = 1, 2, \dots, n$  dengan  $n$  jumlah observasi (Bowerman & O'Connell, 1993, hal. 570).

Prosedur peramalan dengan metode ARIMA mengikuti tahap berikut :

a. Tahap Identifikasi Model

Pada tahap ini akan dilakukan pengecekan kestasioneritasan data dalam varians dan mean, selanjutnya dilakukan identifikasi pola data untuk membentuk model  $p$  dan  $q$  yang sesuai. Tahap ini meliputi beberapa langkah yakni membuat plot data dan memilih transformasi yang sesuai serta menghitung *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data awal untuk mengkonfirmasi orde *differencing* sampai data tersebut stasioner. Selanjutnya menghitung ACF dan PACF dari data yang ditransformasi dan *differencing* untuk mengidentifikasi orde  $p$  dan  $q$  serta menentukan nilai *trend* ketika  $d > 0$ . Adapun karakteristik dari ACF dan PACF teoritis untuk proses stasioner yang dijelaskan dalam Tabel 2.1 dan Tabel 2.2.

**Tabel 2.1** Karakteristik ACF dan PACF Teoritis untuk Proses *Non*-musiman

Proses	ACF	PACF
$AR(p)$	Turun cepat secara eksponensial	<i>Cuts off</i> setelah lag $p$
$MA(q)$	<i>Cuts off</i> setelah lag ke- $q$	Turun cepat secara eksponensial
$AR(p)$ atau $MA(q)$	<i>Cuts off</i> setelah lag ke- $q$	<i>Cuts off</i> setelah lag ke- $p$
$ARMA(p,q)$	Turun cepat secara eksponensial	Turun cepat secara eksponensial

**Tabel 2.2** Karakteristik ACF dan PACF Teoritis untuk Proses musiman

Proses	ACF	PACF
$AR(P)^L$	Turun cepat secara eksponensial pada lag musiman	<i>Cuts off</i> setelah lag $PL$
$MA(Q)^L$	<i>Cuts off</i> setelah lag ke- $QL$	Turun cepat secara eksponensial
$AR(P)^L$ atau $MA(Q)^L$	<i>Cuts off</i> setelah lag ke- $QL$	<i>Cuts off</i> setelah lag ke- $PL$
$ARMA(P,Q)^L$	Turun cepat secara eksponensial pada lag musiman	Turun cepat secara eksponensial pada lag musiman

Sumber : Bowerman & O'Connell, 1993, hal 573-574,

b. Tahap estimasi parameter

Pada tahap ini akan dilakukan pengestimasi parameter dan pengujian signifikansi parameter dari model yang diperoleh pada tahap identifikasi dengan  $\hat{Z}_t = E(Z_t)$  dan  $\hat{\sigma}_a^2 = E(a_t^2)$  dimana  $\{a_t\}$  i.i.d.  $N(0, \hat{\sigma}_a^2)$  *white noise*. Banyak metode estimasi parameter yang digunakan namun metode penaksiran parameter yang sering digunakan adalah *conditional least square* (CLS). Metode ini bekerja dengan membuat *error* yang tidak diketahui sama dengan nol dan meminimumkan *Sum Square error* (SSE) (Cryer dan Chan, 2008, hal. 154).

c. Tahap cek diagnosa

Pada tahap ini akan dilakukan pengecekan kesesuaian model yang diestimasi dengan data yang dimodelkan dimana residual yang dihasilkan harus memenuhi asumsi *white noise* serta berdistribusi normal. Untuk pengecekan *error* digunakan histogram dari *error* yang distandarisasi dan membandingkan dengan distribusi standar normal menggunakan uji *chi-square goodness of fit* atau Tukey's. Untuk pengecekan varians digunakan plot residual. Untuk mengetahui apakah residual *white noise* dengan menghitung signifikansi sample ACF dan PACF.

d. Pemilihan model terbaik

Pada tahap ini akan dilakukan pemilihan model terbaik dari masing-masing model yang telah memenuhi asumsi *white noise* dan distribusi normal. Pemilihan model terbaik ini berdasarkan kriteria *Root Mean Square Error* (RMSE), *Akaike's Information Criterion*(AIC) dan *symmetric Mean Absolute Percentage Error* (sMAPE)

e. Peramalan

Pada tahap ini akan dilakukan peramalan terhadap model yang sesuai dengan menggunakan pendekatan nilai harapan bersyarat.

### 2.3 Model ARIMAX

Model ARIMA dengan penambahan variabel eksogen dikatakan sebagai model ARIMAX (Cryer & Chan, 2008). Dalam pemodelan, efek dari variasi kalender merupakan variabel eksogen dimana model ARIMA dapat dibentuk kedalam model regresi time series dengan penambahan order ARIMA. Bentuk umum dari model ARIMAX dengan efek variasi kalender dapat dilihat pada persamaan (2.5)

$$Y_t = \mu t + \sum_{j=1}^J \beta_j V_{j,t} + \sum_{m=1}^M \delta_m M_{m,t} + \frac{\theta_q(B)\Theta_Q(B^L)}{\phi_p(B)\Phi_P(B^L)(1-B)^d(1-B^L)^D} a_t \quad (2.5)$$

dengan  $V_{j,t}$  merupakan variabel *dummy* untuk  $j$  efek variasi kalender dan  $M_{m,t}$  adalah variabel *dummy* untuk efek musiman.

Penelitian dengan menggunakan model ARIMAX dengan langkah-langkah sebagai berikut:

- a. Menentukan variabel *dummy* berdasarkan periode variasi kalender pada persamaan (2.6)

$$\begin{aligned} M_{1,t} &= \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah Januari} \\ 0, & \text{lainnya} \end{cases} \\ &\vdots \\ M_{12,t} &= \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah Desember} \\ 0, & \text{lainnya,} \end{cases} \end{aligned} \quad (2.6)$$

dimana  $M_{m,t}$  adalah variabel *dummy* untuk pengaruh efek bulanan,



$$\begin{aligned}
V_{j,t} &= \begin{cases} 1, & \text{efek Idul Fitri pada minggu ke-}j \text{ pada bulan terjadinya Idul Fitri} \\ 0, & \text{lainnya} \end{cases} \\
V_{j,t-1} &= \begin{cases} 1, & \text{efek satu bulan sebelum Idul Fitri pada minggu ke-}j \\ 0, & \text{lainnya} \end{cases} \\
V_{j,t+1} &= \begin{cases} 1, & \text{efek satu bulan setelah Idul Fitri pada minggu ke-}j \\ 0, & \text{lainnya.} \end{cases}
\end{aligned} \tag{2.7}$$

Persamaan (2.7) merupakan variabel *dummy* yang menggambarkan efek variasi kalender dari Idul Fitri yang berkaitan dengan minggu terjadinya Idul Fitri dimana  $j=1,2,3,4$  pada satu bulan sebelumnya ( $t-1$ ) maupun satu bulan setelah Idul Fitri ( $t+1$ )

- b. Memodelkan pengaruh variasi kalender dengan menggunakan model persamaan (2.8)

$$Y_t = \alpha + \sum_{j=1}^4 \gamma_j V_{j,t+1} + \sum_{j=1}^4 \delta_j V_{j,t} + \sum_{j=1}^4 \theta_j V_{j,t-1} + \frac{\theta_q(B)\Theta_Q(B^L)}{w_p(B)\Phi_P(B^L)(1-B)^d(1-B^L)^D} a_t \tag{2.8}$$


- c. Mendapatkan model ARIMA yang terbaik dengan menggunakan prosedur Box-Jenkins
- d. Memodelkan data real dengan menambahkan variabel *dummy* sebagai *input* secara simultan dengan menggunakan order ARIMA yang diperoleh sebelumnya. Plotting ACF dan PACF dari residual  $a_{i,t}$  dimana jika residual dependen, maka orde model regresi ditambahkan berdasarkan identifikasi ACF dan PACF sampai diperoleh residual yang independen.
- e. Melakukan uji signifikansi parameter dan uji diagnostik sampai diperoleh proses yang stasioner dan residual yang *white noise*

## 2.4 Metode Neural Network

*Neural network* (NN) pertama kali diperkenalkan oleh McCulloch dan Pitt pada tahun 1943. McCulloch dan Pitt mengajukan unit basis binari sebagai model komputasi untuk NN. Model ini menghitung jumlah dari  $n$  sinyal *input*  $j=1,2,...,n$  yang diberi bobot dan menghasilkan nilai 1 bila jumlah tersebut diatas batas tertentu dan 0 bila dibawah batas tersebut. Secara matematis model NN didefinisikan dalam persamaan (2.14)

$$\hat{Y}_t = f^0 \left[ s_0 + \sum_{j=1}^J \left( s_j f^h \left( x_{j0} + \sum_{i=1}^I x_{ji} X_{i,t} \right) \right) \right] \quad (2.14)$$

dengan  $s_j$  adalah bobot dari neuron ke- $j$  pada *hidden layer*,  $x_{ji}$  adalah bobot dari *input* ke- $i$  untuk neuron ke- $j$  pada *hidden layer*,  $f^h(\bullet)$  adalah fungsi aktivasi pada *hidden layer* dan  $f^0(\bullet)$  adalah fungsi aktivasi pada *layer output*. Arsitektur model NN dapat dilihat pada Gambar 2.1



**Gambar 2.1** Arsitektur Model NN

Berdasarkan Arsitektur model NN pada Gambar 2.1, Neuron merupakan unit pemroses informasi dalam operasi NN. Elemen-elemen dasar model neuron adalah:


1. *Set synapsis* atau *link* penghubung yang ditandai dengan adanya bobot atau kekuatan dari *link* ini.
  2. Penambah yaitu untuk menjumlahkan sinyal *input* yang diberi bobot.
  3. Fungsi aktivasi yaitu untuk membatasi besarnya output dari suatu neuron
- Adapun jenis-jenis fungsi aktivasi yang bisa dipakai dalam NN yakni

1. Fungsi *Threshold*

Ada dua output untuk fungsi *threshold* yakni

$$\{ (v) = \begin{cases} 1, & \text{jika } v \geq 0 \\ 0, & \text{jika } v < 0 \end{cases} \quad (2.15)$$

Bentuk arsitektur fungsi *threshold* dapat dilihat pada Gambar 2.2




**Gambar 2.2** Fungsi *Threshold* (Sumber: *Neural Network Toolbox*, hal. 14-75, 2002)

## 2. Fungsi *Linear Piecewise*

Bentuk matematis dari fungsi linear *piecewise* dapat dilihat pada Persamaan 2.18

$$\phi(v) = \begin{cases} 1, & v \geq \frac{1}{2} \\ v + \frac{1}{2}, & -\frac{1}{2} < v < \frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (2.16)$$

Bentuk arsitektur fungsi *linear piecewise* dapat dilihat pada Gambar 2.3




**Gambar 2.3** Fungsi *Linear Piecewise* (Sumber: Haykin, hal.13, 1999)

## 3. Fungsi *Sigmoid*

Bentuk matematis dari fungsi *sigmoid* dapat dilihat pada Persamaan 2.17

$$\phi(a) = \frac{1}{1 + \exp(-a)} \quad (2.17)$$

dimana  $a > 0$  yang merupakan parameter kemiringan (*slope*) dari fungsi *sigmoid*. Dengan memvariasikan nilai  $a$ , akan diperoleh fungsi *sigmoid* dengan kemiringan yang berbeda-beda. Bentuk arsitektur fungsi sigmoid disajikan pada Gambar 2.4



**Gambar 2.4** Fungsi Sigmoid (Sumber: *Neural Network Toolbox*, hal. 11-126, 2002)


#### 4. Fungsi Tangen Hiperbolik

Bentuk matematis dari fungsi tangen hiperbolik dapat dilihat pada Persamaan 2.18

$$f(x) = a \tanh(b x); a, b > 0$$

$$f(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (2.18)$$

Bentuk arsitektur fungsi tangen hiperbolik dapat dilihat pada gambar 2.5




**Gambar 2.5** Fungsi Tangen Hiperbolik (Sumber: *Neural Network Toolbox*, hal.14-254, 2002)

#### 5. Fungsi Gaussian

Bentuk matematis dari fungsi *Gaussian* dapat dilihat pada Persamaan 2.19

$$f(x) = e^{-x^2/2}. \quad (2.19)$$

Bentuk arsitektur fungsi *Gaussian* dapat dilihat pada gambar 2.6




**Gambar 2.6** Fungsi Gaussian (Sumber: Fauset, hal.315, 1994)

Dalam NN dikenal istilah perceptron yang merupakan bentuk desain NN yang digunakan untuk mengelompokkan objek dari dua kelas yang bisa dipisahkan secara linear. Rosenblatt membuktikan bahwa jika data yang digunakan untuk mentraining perceptron tersebut diambil secara random dari himpunan objek dua kelas yang bisa dipisahkan secara linear, algoritma perceptron akan mencapai konvergensi. Sebuah perceptron dapat menghasilkan satu atau lebih output. Masing-masing output memiliki bias dan himpunan bobot yang terpisah. Perceptron dibagi atas dua bagian yakni :


1. *Single layer perceptron*

Pada *single layer perceptron* bentuk desain NN yang paling sederhana digunakan untuk mengelompokkan obyek dari dua kelas yang bisa dipisahkan secara linear. Perceptron dengan fungsi aktivasi linear adalah model regresi linear (Weisberg 1985; Myers, 1986), perceptron dengan fungsi aktivasi logistik adalah model regresi logistik (Hosmer dan Lemeshow 1989), dan perceptron dengan fungsi aktivasi *threshold* adalah fungsi diskriminan linear (Hand 1981; McLachlan 1992; Weiss dan Kulikowski 1991). Bentuk arsitektur perceptron dengan fungsi aktivasi linear dapat dilihat pada Gambar 2.7



**Gambar 2.7** *Simple Linear Perceptron* (Sumber: Sarle, hal.3, 1994)


Bentuk arsitektur perceptron dengan fungsi aktivasi logistik dapat dilihat pada Gambar 2.8



**Gambar 2.8** Simple Nonlinear Perceptron (Sumber: Sarle, hal.3, 1994)

## 2. Multilayer Perceptron (MLP)

MLP merupakan model yang diperoleh dari hasil transformasi neuron dimana bobot yang diestimasi antara *input* dan *hidden layer* menggunakan fungsi aktivasi non-linear. Perbedaan mendasar antara MLP dan *single layer* perceptron adalah terdapatnya *hidden layer* pada MLP. MLP dapat juga memiliki lebih dari satu *input* dan *output* dengan jumlah neuron pada *hidden* dapat lebih sedikit dari jumlah *input* atau *output* (Sarle, 1994). Bentuk arsitektur *multilayer* perceptron dapat dilihat pada Gambar 2.9



**Gambar 2.9** Bentuk Transformasi dari Multilayer Perceptron (Sumber: Sarle, hal.4, 1994)

Salah satu metode untuk mentraining *multilayer neural networks* adalah algoritma *backpropagasi*. Menurut Fauset (1994), algoritma pelatihan *backpropagation* pada dasarnya terdiri dari tiga tahapan, yaitu:

1. *Input* nilai data pelatihan/*training* sehingga diperoleh nilai *output*,
2. Propagasi balik dari nilai *error* yang diperoleh,
3. Penyesuaian bobot koneksi untuk meminimalkan nilai *error*.

Algoritma pelatihan *Backpropagation* terdiri dari dua proses, *feedforward* dan *backpropagation* dari *error*. Istilah *feedforward* digunakan ketika adanya proses penginputan data dari *input layer* ke *hidden layer* dan sebaliknya dari *hidden layer* ke *input layer*, sedangkan *backpropagation* merupakan algoritma *training* yang terdiri dari dua proses yakni *feedforward* nilai-nilai yang ada dan menghitung *error* serta menyebarkannya kembali ke layer awal. Dengan kata lain *feedforward* merupakan bagian dari algoritma *backpropagation*. Proses *feedforward* dikenal dengan *fase 1* dan proses *backpropagation* dikenal dengan *fase 2*. Adapun *fase 3* yang merupakan *fase* perbaikan bobot dan bias. Berikut akan dijelaskan *fase 1*, *fase 2* dan *fase 3* (Fausset, 1994, hal. 294):

Fase 1:

- a. Masing-masing *input* unit ( $X_i, i=1,2,...,n$ ) mengirim sinyal *input* dan menyebarkannya pada *hidden layer*
- b. Masing-masing *hidden* unit ( $Z_j, j=1,2,...,p$ ) menjumlahkan semua sinyal *input* yang telah dikalikan dengan faktor penimbang/bobot koneksi serta ditambah dengan bias  $z\_in_j = x_{oj} + \sum_{i=1}^n x_i x_{ij}$ , dan menghitung sinyal *output* sesuai dengan fungsi aktivasi yang digunakan  $z_j = f(z\_in_j)$ , kemudian mengirim sinyal tersebut ke semua unit pada layer berikutnya (*output units*)
- c. Masing-masing *output* unit ( $Y_k, k=1,2,...,m$ ), menjumlahkan semua sinyal *input* yang masing-masing telah dikalikan dengan faktor penimbang/bobot koneksinya serta ditambah bias  $y\_in_k = s_{ok} + \sum_{j=1}^p z_j s_{jk}$ , menghitung sinyal *output* sesuai dengan fungsi aktivasi yang digunakan dimana  $y_k = f(y\_in_k)$ .

Fase 2 :

- a. Menghitung informasi *error* pada masing-masing *output* unit ( $Y_k, k=1,2,...,m$ ),  $u_k = (t_k - y_k) f'(y\_in_k)$ , menghitung perbaikan bobot yang akan

digunakan untuk memperbaiki  $s_{jk}$  dengan laju percepatan  $a$  dimana  $\Delta s_{jk} = r \cdot u_k \cdot z_j$ , menghitung nilai koreksi biasnya  $\Delta s_{0k} = r u_k$  dan mengirim  $u_k$  pada semua unit layer sebelumnya.

- b. Setiap unit-unit *hidden layer* ( $Z_j, j=1,2,...,p$ ) menjumlahkan  $u_k$  masukannya (dari unit-unit pada layer di atasnya) dimana  $u_{in_j} = \sum_{k=1}^m u_k s_{jk}$ , dikalikan dengan turunan dari fungsi aktivasinya untuk menghitung *error*-nya dimana  $u_j = u_{in_j} f'(z_{in_j})$ , menghitung koreksi bobotnya yang (digunakan untuk memperbaiki  $x_{ij}$ ) dimana  $\Delta x_{ij} = r \cdot u_j x_i$ , dan menghitung koreksi biasnya (untuk memperbaiki  $x_{0j}$ ) dimana  $\Delta x_{0j} = r u_j$ .

Fase 3 :

- a. Setiap *output unit* ( $Y_k, k=1,2,...,m$ ) memperbaiki bias dan bobotnya ( $j=0,...,p$ ) dengan  $s_{jk}(\text{new}) = s_{jk}(\text{old}) + \Delta s_{jk}$ ,
- b. Setiap *hidden unit* ( $Z_j, j=1,2,...,p$ ) memperbaiki bias dan bobotnya ( $i=0,...,n$ ) dengan  $x_{ij}(\text{new}) = x_{ij}(\text{old}) + \Delta s_{ij}$ .

Algoritma *backpropagation* secara lengkap mengikuti tahapan berikut:

1. Inisialisasi bobot (ambil bobot awal dengan nilai random yang cukup kecil),
2. Untuk masing-masing pasangan data pelatihan (*training data*) lakukan langkah *Fase 1, Fase 2 dan Fase 3* yang dijelaskan sebelumnya sampai kondisi akhir iterasi dipenuhi atau *stopping error* dicapai,
3. Uji kondisi berhenti  
Jika kondisi berhenti telah terpenuhi yakni *stopping error* sudah dicapai atau pelatihan sampai pada akhir iterasi, maka pelatihan *network* dapat dihentikan.

Parameter NN dapat juga diestimasi dengan menggunakan algoritma *supervised learning*. Algoritma ini menggunakan perbandingan antara *output* yang dihasilkan dengan prediksi. Langkah-langkah yang dilakukan selama proses training adalah sebagai berikut:



1. NN menghitung *output* prediksi  $\hat{Y}$  berdasarkan *input* X yang diberikan dan bobot sementara
2. Perbedaan antara *output* prediksi dan observasi diukur dengan menggunakan fungsi *error*

$$E = \frac{1}{2} \sum_{t=1}^n [Y_t - \hat{Y}_t]^2 \quad (2.21)$$

3. Semua bobot diperoleh berdasarkan aturan algoritma *learning*
4. Proses berhenti ketika semua kriteria telah terpenuhi

## 2.5 Quantiles Regression

Metode QR diperkenalkan pertama kali oleh Roger Koenker dan Gilbert Basset pada tahun 1978. QR merupakan perluasan model regresi pada kuantil bersyarat dimana distribusi kuantil bersyarat dari variabel respon dinyatakan sebagai fungsi dari kovariat yang diamati. Pendekatan ini memungkinkan menduga fungsi kuantil dari sebaran bersyarat respon pada berbagai atau setiap nilai kuantil yang diinginkan dari peneliti (Chen dan Wei, 2005). Estimasi parameter pada QR dapat dilakukan dengan beberapa metode, seperti pendekatan *direct*, *rank-score*, dan *resampling* (Koenker, 2005). QR sangat berguna dalam berbagai bidang yaitu ekonometrika, biomedik, keuangan, kesehatan, lingkungan, dan sebagainya.

Misalkan diberikan data  $\{y_1, y_2, \dots, y_t\}$  dengan  $t=1, 2, 3, \dots, n$  merupakan himpunan berpasangan variabel random yang terdistribusi secara independen dan tidak identik dengan kuantil  $\dagger \in (0, 1)$  dan fungsi distribusi  $F_Y$  maka bentuk umum dari fungsi invers  $F_Y$  adalah  $F_Y^{-1}(\dagger) = \inf \{t \in \mathbb{R} : F_Y(t) \geq \dagger\}$  yang merupakan fungsi kuantil ke  $\dagger$  yang didefinisikan sebagai  $q_{\dagger} = F_Y^{-1}(\dagger)$ . Misalkan terdapat model linear dengan  $y_t = S_{\dagger,0} + S_{\dagger,1}x_{1t} + S_{\dagger,2}x_{2t} + \dots + S_{\dagger,k}x_{kt} + e_t$  dimana  $S_0$  adalah parameter konstan dan  $e_t$  adalah *error* yang identik dan independen, maka kuantil bersyarat  $q_{\dagger}(X)$  dari distribusi bersyarat  $F_{Y|X}$  didefinisikan dalam Persamaan 2.30

$$q_{\dagger}(X) = F_{Y|X}^{-1}(\dagger) = \inf \{t \in \mathbb{R} : F_{Y|X}(t) \geq \dagger\}, \quad (2.30)$$

yang dapat diperoleh dengan meminimumkan bentuk Persamaan 2.31

$$\min_{S \in \mathbb{R}} \left( \sum_{t|y_t \geq S} \dagger |y_t - x_t^T S| + \sum_{t|y_t < S} (1-\dagger) |y_t - x_t^T S| \right) \quad (2.31)$$

QR merupakan pengembangan dari QR median. Regresi OLS diestimasi dengan meminimumkan jumlah kuadrat residual, sedangkan QR akan meminimumkan jumlah absolut residual yang lebih dikenal dengan *Least Absolute Deviation* (LAD).

Taylor dan Bunn (1999) menggunakan estimasi QR pada error untuk meningkatkan keakuratan peramalan interval. Estimasi QR ditujukan pada error peramalan bukan pada observasi  $Y_t$ . Masalah minimisasi digunakan untuk menentukan kuantil ke- $\dagger$ . Misalkan diberikan model sistematis heteroskedastis sebagai berikut

$$y_t = \mu_t(x_t) + \sigma_t(x_t)e_t \quad (2.32)$$


dimana  $x_t$  adalah vektor baris dari variabel penjelas,  $\mu_t(x_t)$  adalah mean bersyarat dari proses regresi,  $\sigma_t(x_t)$  adalah varians bersyarat dan  $e_t$  adalah *error* independen dari vektor  $x_t$  maka kuantil ke- $\dagger$  dari  $e_t$  didefinisikan sebagai nilai  $Q_e(\dagger)$  dimana  $P(e_t < Q_e(\dagger)) = \dagger$ . Fungsi kuantil bersyarat dari  $y_t$  adalah sebagai berikut:

$$Q_{y_t}(\dagger | x_t) = \mu_t(x_t) + \sigma_t(x_t) Q_e(\dagger) \quad (2.33)$$

$$Q_{y_t}(\dagger | x_t) = x_t S + (1 + x_t X) Q_e(\dagger) \quad (2.34)$$

$$Q_{y_t}(\dagger | x_t) = x_t S(\dagger) \quad (2.35)$$

dengan  $S, X$  adalah parameter vektor pada kuantil  $\dagger$ .



**Gambar 2.10.** *Loss Function*

Gambar 2.10 menjelaskan pemberian bobot pada residual QR dimana bobot yang digunakan yakni  $\dagger$  untuk nilai residual yang lebih besar atau sama dengan nol dan  $(1-\dagger)$  untuk nilai residual yang kurang dari nol (Konker and Hallock, 2001, hal. 3). Perkalian antara residual dan dengan bobot yang diberikan membentuk *loss function* ( $\dots(\dagger)$ ) yaitu:

$$\dots(\dagger)(v) = \sum_{i=1, v_i \geq 0}^n \dagger |v_i| + \sum_{i=1, v_i < 0}^n (1-\dagger) |v_i| \quad (2.36)$$

Sehingga untuk mendapatkan penduga  $\hat{S}(\dagger)$  dilakukan dengan meminimumkan *loss function* yakni

$$\begin{aligned} \hat{S}(\dagger) &= \min_S \sum_{i|y_i \geq x_i S}^n \dots(\dagger)(v_i) \\ &= \min_S \sum_{i|y_i \geq x_i S}^n \dots(\dagger)(y_i - x_i S) \end{aligned} \quad (2.37)$$

dimana  $\dagger \in (0,1)$  dan

$$\dots(\dagger)(v) = \begin{cases} \dagger v & , \text{jika } v \geq 0 \\ (\dagger - 1)v & , \text{jika } v < 0 \end{cases} \quad (2.38)$$

maka persamaan (2.35) dapat dinyatakan sebagai

$$\hat{S}(\dagger) = \min_S \left\{ \dagger \sum_{i|y_i \geq x_i S}^n |y - x_i S| + (1-\dagger) \sum_{i|y_i < x_i S}^n |y - x_i S| \right\} \quad (2.39)$$

## 2.6 Model Hybrid QRNN

NN merupakan salah satu model nonlinear dimana memungkinkan estimasi model nonlinear dengan tanpa membutuhkan berbagai asumsi. Tipe NN yang paling banyak digunakan adalah *single hidden layer feedforward network* (Zhang et al., 1998). Model ini terdiri dari himpunan  $n$  input yang mana dihubungkan pada masing-masing  $m$  unit pada *single hidden layer* yang pada akhirnya terhubung pada *output*. *Input* merupakan variabel penjelas  $x_{it}$  dan *output* merupakan variabel dependent  $y_t$ . Model tersebut dapat ditulis seperti pada Persamaan (2.44)

$$f(x_t, v, w) = g_2 \left( \sum_{j=0}^m v_j g_1 \left( \sum_{i=0}^n w_{ji} x_{it} \right) \right), \quad (2.44)$$

dengan  $g_1(\cdot)$  dan  $g_2(\cdot)$  dan adalah fungsi aktivasi, yang mana jumlahnya dipilih berdasarkan fungsi tangen hiperbolik dan linear,  $w_{ji}$  dan  $v_j$  merupakan bobot (parameter) yang diestimasi.

White (1992) memberikan teori yang mendukung penggunaan QR dalam NN untuk estimasi kekuatan model kuantil nonlinear. Model QRNN  $f(x_t, v, w)$  dari kuantil ke- $\dagger$  dapat diestimasi menggunakan bentuk minimum berikut :

$$\left\{ \hat{v}(\dagger), \hat{w}(\dagger) \right\} = \min_{v, w} \left( \sum_{t|y_t \geq f(x_t, v, w)} \dagger |y_t - f(x_t, v, w)| + t \left| \sum_{t|y_t < f(x_t, v, w)} (1-\dagger) |y_t - f(x_t, v, w)| \right| + \right. \\ \left. \dagger_1 \sum_i w_{ji}^2 + \dagger_2 \sum_t v_t^2 \right) \quad (2.45)$$

dimana  $\dagger_1, \dagger_2$  adalah parameter *penalthy regularisation* pada network yang kompleks dan menghindari *overfitting* (Bishop, 1997). Jika  $\dagger_1, \dagger_2 = 0$  maka model Persamaan 2.45 dapat ditulis sebagai berikut:

$$\left\{ \hat{v}(\dagger), \hat{w}(\dagger) \right\} = \min_{v, w} \left( \sum_{t|y_t \geq f(x_t, v, w)} \dagger |y_t - f(x_t, v, w)| + t \left| \sum_{t|y_t < f(x_t, v, w)} (1-\dagger) |y_t - f(x_t, v, w)| \right| \right) \quad (2.46)$$

## 2.7 Bank Indonesia

Sejarah Bank Indonesia sebagai bank sentral yang independen dimulai ketika sebuah Bank Sentral baru Act, UU No. 23/1999 tentang Bank Indonesia, disahkan pada tanggal 17 Mei 1999 dan telah yang telah diubah dengan UU No.6/2009 pada tanggal 15 Januari 2004. Undang-undang tersebut menegaskan bahwa Bank Indonesia memiliki status dan posisi sebagai lembaga negara yang independen dan bebas dari campur tangan pemerintah atau pihak eksternal lainnya. Sebagai lembaga negara yang independen, Bank Indonesia sepenuhnya otonom dalam merumuskan dan melaksanakan setiap tugas dan kewenangan sebagaimana diatur dalam Undang-Undang. Pihak eksternal secara ketat dilarang mengganggu pelaksanaan tugasnya, dimana Bank Indonesia memiliki tugas untuk menolak atau mengabaikan setiap upaya campur tangan dalam bentuk apapun

oleh pihak manapun. Bank Indonesia (BI) merupakan bank sentral Republik Indonesia yang mempunyai satu tujuan tunggal, yaitu mencapai dan memelihara kestabilan nilai rupiah. Bank sentral memiliki wewenang untuk mengeluarkan dan mengedarkan uang kartal yang terdiri dari uang kertas dan uang logam.

Pengedaran uang rupiah dilakukan oleh Bank Indonesia sesuai dengan kebutuhan jumlah uang beredar. Uang beredar sering dikaitkan dengan suku bunga, pertumbuhan ekonomi, perkembangan harga yang dihitung melalui indeks harga konsumen, tingkat inflasi, dan sebagainya. Jumlah uang beredar jika terlalu banyak dapat mendorong kenaikan harga barang secara umum (inflasi). Sebaliknya, apabila jumlah uang beredar terlalu sedikit maka kegiatan ekonomi akan sulit. Oleh karena itu, jumlah uang beredar perlu diatur agar sesuai dengan kapasitas ekonomi. Peningkatan kebutuhan uang kartal biasanya terjadi selama periode hari raya keagamaan seperti Idul Fitri, Natal, dan Imlek. Kebutuhan uang kartal juga cenderung tinggi pada akhir tahun, masa libur sekolah, dan tahun ajaran baru (Bank Indonesia, 2013). Untuk memenuhi jumlah uang beredar, maka masalah yang dihadapi adalah sulitnya memperkirakan jumlah uang yang berada di tangan masyarakat atau sering disebut sebagai *autonomous liquidity factor*. Untuk dapat memenuhi tujuan tersebut, maka salah satu segmen yang senantiasa dipantau oleh BI adalah *outflow* dan *inflow* uang kartal. Hal ini dilakukan agar BI dapat mengambil kebijakan terhadap proses percetakan uang, serta mengatur uang yang keluar masuk pada BI. Pemantauan *inflow-outflow* uang kartal salah satunya dengan melakukan peramalan *inflow* dan *outflow* uang kartal.

## BAB III

### METODOLOGI PENELITIAN

#### 3.1 Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari bank Indonesia untuk Provinsi NTT dan Nasional. Data dibagi dalam *in-sample* dan *out-sample* data. Pembagian data ini dimaksudkan agar model yang diperoleh memiliki kemampuan generalisasi yang baik dalam melakukan peramalan data. Data *in-sample* sebanyak 132 yang diambil dari bulan Januari 2005 sampai Desember 2015 sedangkan data *out-sample* sebanyak 12 yang diambil dari bulan Januari sampai Desember 2016. Variabel yang digunakan dalam penelitian ini terdiri dari variabel independen yang merupakan data *inflow* dan *outflow* dan variabel dependen yang merupakan periode waktu ke- $t$  untuk data *inflow* dan *outflow* ke- $i$  serta efek variasi kalender dari Idul Fitri. Notasi yang digunakan untuk melambangkan variabel-variabel tersebut dapat dilihat pada Tabel 3.1 berikut:

**Tabel 3.1** Notasi dan Variabel Penelitian

Variabel	Nama Variabel	Definisi Operasional
$Y_{1t}$	<i>Inflow</i> NTT untuk periode ke- $t$	Kegiatan Bank melakukan penyetoran uang ke BI
$Y_{2t}$	<i>Outflow</i> NTT untuk periode ke- $t$	Kegiatan Bank melakukan penarikan uang yang masih layak edar (ULE)
$Y_{3t}$	<i>Inflow</i> Nasional untuk periode ke- $t$	Kegiatan Bank melakukan penyetoran uang ke BI
$Y_{4t}$	<i>Outflow</i> Nasional untuk periode ke- $t$	Kegiatan Bank melakukan penarikan uang yang masih layak edar (ULE)
$M_{i,t}$	<i>Dummy</i> bulan ke- $i=1,...,12$	<i>Dummy</i> bulan Januari sampai Desember
$t$	Waktu	<i>Dummy</i> waktu untuk bulan
$V_{j,t-1}$	Satu bulan sebelum hari raya Idul Fitri	<i>Dummy</i> minggu sebelum terjadinya hari raya Idul Fitri $j=1,2,3,4$
$V_{j,t}$	Bulan terjadinya hari raya Idul Fitri	<i>Dummy</i> minggu terjadinya hari raya Idul Fitri dimana $j=1,2,3,4$
$V_{j,t+1}$	Satu bulan setelah hari raya Idul Fitri	<i>Dummy</i> minggu setelah terjadinya hari raya Idul Fitri $j=1,2,3,4$

Terjadinya hari raya Idul Fitri yang bervariasi berpengaruh terhadap *inflow* dan *outflow* uang kartal. Informasi tentang hari raya Idul Fitri dapat dilihat pada Tabel 3.2

**Tabel 3.2** Terjadinya Idul Fitri

T	Tahun	Date	Penjelasan
11	2005	03-04 November	Idul Fitri terjadi pada minggu pertama di bulan November
22	2006	23-24 Oktober	Idul Fitri terjadi pada minggu keempat di bulan Oktober
34	2007	12-13 Oktober	Idul Fitri terjadi pada minggu kedua di bulan Oktober
46	2008	01-02 Oktober	Idul Fitri terjadi pada minggu pertama di bulan Oktober
57	2009	21-22 September	Idul Fitri terjadi pada minggu ketiga di bulan September
69	2010	10-11 September	Idul Fitri terjadi pada minggu kedua di bulan September
80	2011	30-31 Agustus	Idul Fitri terjadi pada minggu keempat di bulan Agustus
92	2012	19-20 Agustus	Idul Fitri terjadi pada minggu ketiga di bulan Agustus
104	2013	08-09 Agustus	Idul Fitri terjadi pada minggu kedua di bulan Agustus
115	2014	28-29 Juli	Idul Fitri terjadi pada minggu keempat di bulan Juli
127	2015	16-17 Juli	Idul Fitri terjadi pada minggu ketiga di bulan Juli
139	2016	5-6 Juli	Idul Fitri terjadi pada minggu pertama di bulan Juli

Adapun struktur data yang digunakan dalam penelitian ini yakni dengan melibatkan variabel dummy musiman dan variasi kalender seperti yang terlihat pada Tabel 3.3

**Tabel 3.3** Struktur Data Penelitian

$t$	$Y_1$	...	$Y_4$	$M_1$	$M_2$	...	$M_{12}$	$V_1$	$V_2$	...	$V_4$
1	$Y_{1,1}$	...	$Y_{4,1}$	$M_{1,1}$	$M_{2,1}$	...	$M_{2,1}$	$V_{1,1}$	$V_{2,1}$	...	$V_{4,1}$
2	$Y_{1,2}$	...	$Y_{4,2}$	$M_{1,2}$	$M_{2,2}$	...	$M_{2,2}$	$V_{1,2}$	$V_{2,2}$	...	$V_{4,2}$
3	$Y_{1,3}$	...	$Y_{4,3}$	$M_{1,3}$	$M_{2,3}$	...	$M_{2,3}$	$V_{1,3}$	$V_{2,3}$	...	$V_{4,3}$
$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
$N$	$Y_{1,n}$	...	$Y_{4,n}$	$M_{1,n}$	$M_{2,n}$	...	$M_{2,n}$	$V_{1,n}$	$V_{2,n}$	...	$V_{4,n}$

### 3.2 Langkah analisis

Terdapat 2 pendekatan model *hybrid* yang digunakan dalam penelitian ini yakni model *hybrid* ARIMAX-QR dan model *hybrid* QRNN. Berikut akan dijelaskan langkah-langkah yang dibutuhkan dalam peramalan dengan menggunakan dua pendekatan tersebut

#### 3.2.1 Meramalkan data *inflow* dan *outflow* uang kartal Bank Indonesia dengan menggunakan model *hybrid* ARIMAX-QR

Peramalan data *inflow* dan *outflow* uang kartal pada Bank Indonesia menggunakan model *hybrid* ARIMAX-QR dilakukan dengan tahapan :

##### 1. Peramalan Model Linear

Dalam pemodelan linear ini ada beberapa tahap yang akan dilakukan untuk memperoleh prediksi model ARIMAX yakni:

- Mengidentifikasi pola data melalui *time series* plot
- Menentukan variabel untuk pemodelan pola data pada tahap 1 seperti yang tertulis pada Persamaan (2.6) dan (2.7)



- c. Memodelkan pola data *trend*, musiman dan variasi kalender secara simultan dengan model pola data masing-masing dapat dilihat pada Persamaan (2.11), (2.12) dan (2.13)
- d. Mengecek apakah residual sudah memenuhi asumsi *white noise* jika residual sudah memenuhi asumsi *white noise* maka model yang terbentuk adalah model regresi *time series*, sedangkan jika residual tidak memenuhi asumsi *white noise* maka dilanjutkan ke langkah e.
- e. Memodelkan residual dengan ARIMA melalui prosedur Box-Jenkins
- f. Memodelkan data dengan model ARIMAX pada Persamaan (2.9)
- g. Mendapatkan nilai ramalan atau prediksi untuk model ARIMAX
- h. Melakukan pengecekan heteroskedastisitas dimana jika pada nilai residual terdapat kasus heteroskedastisitas maka dilanjutkan dengan langkah 2

2. Peramalan model *hybrid*

Melakukan pemodelan *time series regression* dengan respon  $Y_t$  dan prediktor  $\hat{Y}_t$  serta variabel *dummy* menggunakan QR dimana

$$Y_t = S_1(\tau) \hat{Y}_t + S_2(\tau) t + x_1(\tau) M_{1,t} + \dots + r_4(\tau) V_{4,t+1} + a_t$$

3. Menghitung estimasi parameter model QR dengan meminimumkan persamaan (2.39)
4. Mendapatkan estimator  $\hat{S}(\tau)$  untuk kuantil 2,5%, 50% dan 97,5%
5. Melakukan peramalan titik dan interval dengan menggunakan model terbaik

### 3.2.2 Meramalkan data *inflow* dan *outflow* uang kartal Bank Indonesia dengan menggunakan model *hybrid* QRNN

Peramalan data *inflow* dan *outflow* uang kartal pada Bank Indonesia menggunakan model *hybrid* QRNN dilakukan dengan tahapan sebagai berikut:

1. Peramalan model linear yakni pemodelan ARIMAX
2. Pembentukan arsitektur model nonlinear

Arsitektur yang digunakan dalam model NN adalah *single hidden layer feedforward network* yang terdiri dari  $n$  input,  $m$  unit pada *hidden layer* dan satu *output*. Dalam regresi *input* dikenal sebagai variabel prediktor  $x_{it}$  dan

*output* dikenal sebagai variabel dependen  $y_t$ . Model yang digunakan adalah sebagai berikut:

$$f(x_t, v, w) = g_2 \left( \sum_{j=0}^m v_j g_1 \left( \sum_{i=0}^n w_{ji} x_{it} \right) \right),$$

dimana  $g_1(\cdot)$  adalah fungsi aktivasi tangen hiperbolik dari *input* ke *hidden layer* dan  $g_2(\cdot)$  adalah fungsi aktivasi linear dari *hidden layer* ke *output*,  $w_{ij}$  dan  $v_j$  adalah bobot atau parameter yang diestimasi. Penentuan  $n$  input dalam arsitektur model nonlinear ini menggunakan nilai prediksi model ARIMAX, sedangkan penentuan  $m$  unit pada *hidden layer* menggunakan metode *cross validation*.

3. Mengestimasi parameter model QRNN  $f(x_t, v, w)$  dengan meminimumkan Persamaan 2.46 dengan nilai  $\beta_1$  dan  $\beta_2$  yang digunakan dalam penelitian ini adalah 0, sedangkan  $v$  untuk setiap iterasi adalah  $2^{-8}, 2^{-9}, 2^{-10}, \dots, 2^{-32}$  menggunakan *package* QRNN.
4. Mendapatkan estimator  $\{\hat{v}(\dagger), \hat{w}(\dagger)\}$  untuk kuantil 2,5%, 50% dan 97,5%
5. Melakukan peramalan titik dan interval dengan menggunakan model terbaik

### 3.2.3 Pemilihan model terbaik

Pemilihan model terbaik menggunakan kriteria sebagai berikut

- a. *Root Mean Square Error* (RMSE) untuk data outsample dinyatakan dalam Persamaan 3.1:

$$RMSE = \sqrt{\frac{1}{M} \sum_{l=1}^M (Y_{n+l} - \hat{Y}_n(l))^2} \quad (3.1)$$

dimana  $M$  merupakan banyaknya ramalan,  $Y_{n+l}$  merupakan deret output pada waktu ke- $(n+l)$  dan  $\hat{Y}_n(l)$  merupakan nilai ramalan deret output  $l$  tahap kedepan, sedangkan RMSE untuk data insample dinyatakan dalam Persamaan 3.2


$$RMSE = \sqrt{\frac{1}{M-p} \sum_{l=1}^M (Y_{n+l} - \hat{Y}_n(l))^2} \quad (3.2)$$

dimana  $p$  adalah jumlah parameter

b. *Median Absolut Error* (MdAE) yang dinyatakan dalam persamaan

$$\text{MdAE} = \text{median}(|e_t|) \quad (3.2)$$

Langkah analisis menggunakan metode *hybrid* ARIMAX-QR dan QRNN dapat digambarkan dalam diagram alir pada gambar 3.1



**Gambar 3.1** Diagram Alir Langkah Analisis Menggunakan Model *Hybrid* ARIMAX-QR dan QRNN

## BAB 4

### HASIL DAN PEMBAHASAN

Pada bab ini dilakukan analisis data *inflow* dan *outflow* uang kartal di BI Provinsi NTT dan Nasional yang diawali dengan melakukan studi simulasi, eksplorasi data serta pemodelan dan peramalan menggunakan metode ARIMAX-QR dan QRNN.

#### 4.1. Studi Simulasi

Studi simulasi merupakan salah satu cara untuk membuktikan suatu metode memang layak digunakan. Pada bagian pertama ini akan dilakukan studi simulasi untuk mengidentifikasi terjadinya nonlinearitas dan heteroskedastisitas pada data.

##### 4.1.1 Simulasi Data Bangkitan

Pada penelitian ini dilakukan simulasi data yang mengandung komponen untuk pola tren, komponen untuk pola musiman (bulan) dan komponen untuk efek variasi kalender (hari raya Idul Fitri) serta mengandung residual. Ukuran sampel yang digunakan dalam penelitian ini sebesar 144 dengan replikasi sebanyak 5. Model matematis untuk data simulasi yang mengandung keempat komponen tersebut adalah sebagai berikut:

$$Y_t = T_t + S_t + V_t + N_{t,t} \quad (4.1)$$

Dengan:

$$T_t = 0,15t \quad (4.2)$$

$$S_t = 7M_{1,t} + 10M_{2,t} + 12M_{3,t} + 11M_{4,t} + 8M_{5,t} + 7M_{6,t} \\ + 6M_{7,t} + 4M_{8,t} + 2M_{9,t} + 3M_{10,t} + 5M_{11,t} + 6M_{12,t} \quad (4.3)$$


$$V_t = 8V_{1,t} + 16V_{2,t} + 26V_{3,t} + 34V_{4,t} + 29V_{1,t-1} \\ + 21V_{2,t-1} + 11V_{3,t-1} + 8V_{4,t-1} \quad (4.4)$$

$$N_{1,t} = 0,7N_{1,t-1} + a_t \text{ dengan } a_t \sim N(0;1,2^2) \quad (4.5)$$

$$N_{2,t} = 6,5N_{1,t-1} \exp(-0,25N_{1,t-1}^2) + a_t \text{ dengan } a_t \sim iidn(0;1,3^2) \quad (4.6)$$

dimana  $T_t$  merupakan komponen untuk tren,  $S_t$  merupakan komponen untuk musiman,  $V_t$  merupakan komponen untuk variasi kalender dan  $N_t$  merupakan komponen untuk residual yang mengikuti proses linear dan nonlinear.


Komponen untuk pola tren, musiman maupun variasi kalender (saat Idul Fitri maupun sebelum Idul Fitri) disajikan dalam plot terpisah untuk melihat bagaimana pengaruh masing-masing komponen setelah digabungkan menjadi  $Y_t$ . Berikut merupakan plot untuk komponen tren, komponen musiman yang bersifat homogen maupun heterogen dan komponen variasi kalender:



**Gambar 4.1.** Plot untuk Komponen Tren (a), Pola Musiman Homogen (b), Pola Musiman Heterogen (c), Efek Variasi Kalender (d)


Berdasarkan plot yang terbentuk, terlihat bahwa pengaruh tertinggi dalam pembentukan  $Y_t$  adalah komponen tren serta efek variasi kalender. Komponen tren menyebabkan nilai  $Y_t$  selalu meningkat secara linear begitu pula komponen efek variasi kalender menyebabkan  $Y_t$  meningkat signifikan pada saat hari raya Idul Fitri maupun sebelum hari raya Idul Fitri. Berbeda dengan komponen untuk pola musiman yang bersifat homogen memberikan pengaruh yang tidak terlalu

signifikan terhadap pembentukan  $Y_t$ . Hal demikian terjadi pula pada komponen residual dimana komponen residual terlihat memberikan pengaruh yang paling kecil terhadap pembentukan nilai  $Y_t$ . Komponen residual yang digunakan dalam pembentukan  $Y_t$  meliputi komponen linear dan komponen nonlinear. Visualisasi pengaruh komponen residual dilihat pada Gambar 4.2.



**Gambar 4.2** Komponen Residual dengan Pola Linear (a) dan Nonlinear (b)

Berdasarkan plot yang terbentuk pada Gambar 4.2 terlihat bahwa komponen residual yang mengikuti pola linear maupun nonlinear memberikan pengaruh yang paling kecil dalam pembentukan  $Y_t$ . Untuk melihat apakah residual mengikuti model linear maupun nonlinear maka dapat dilihat melalui plot antara residual dari proses regresi *time series* dengan lag 1 yang ditunjukkan pada Gambar 4.3



**Gambar 4.3** Plot Residual dari Proses Regresi *Time Series* yang Mengikuti Model Linear dengan Lag 1 (a) dan Nonlinear (b)


Berdasarkan plot yang terbentuk pada Gambar 4.3 terlihat bahwa residual dari proses regresi *time series* mengikuti pola linear dan nonlinear. Pada Gambar

4.3 (a) terlihat bahwa hubungan antara residual dari proses regresi *time series* dengan lag 1 adalah linear. Sedangkan plot yang terbentuk pada Gambar 4.3 (b) terlihat bahwa hubungan antara residual dari proses regresi *time series* dengan lag 1 adalah nonlinear.

Simulasi yang dibentuk pada penelitian ini melibatkan 4 skenario yaitu pola musiman bersifat homogen maupun heterogen serta residual dari regresi *time series* yang mengikuti model linear dan nonlinear. Masing-masing skenario dilakukan pengulangan sebanyak 5 kali dengan membangkitkan  $a_t$  yang membangun nilai untuk komponen residual dari proses regresi *time series*. Berikut akan dijelaskan cara kerja dari masing-masing skenario:

#### 1. Skenario 1

Pada skenario 1, simulasi dilakukan dengan membangkitkan komponen untuk pola tren (Persamaan 4.2), komponen untuk pola musiman dalam bentuk dummy bulan yang bersifat homogen (Persamaan 4.3) dan komponen variasi kalender saat hari raya Idul Fitri maupun satu bulan sebelum hari raya Idul Fitri (Persamaan 4.4), dengan residual dari regresi *time series* mengikuti model linear (Persamaan 4.5). Secara visual *time series* plot serta boxplot dari model rekonstruksi pada skenario 1 dapat dilihat pada Gambar 4.4




**Gambar 4.4** Plot *Time Series* pada Skenario 1 (a) dan Boxplot (b)

Pola data pada skenario pertama memiliki kesamaan setiap tahunnya, dimana pada bulan-bulan saat terjadinya Idul Fitri memiliki nilai yang lebih tinggi dibandingkan bulan lainnya. Data simulasi tertinggi pada bulan Juli 2014 yaitu saat hari raya Idul Fitri berdasarkan Gambar 4.4 (a). Berdasarkan Gambar 4.4 (b)

boxplot yang terbentuk terlihat bahwa lebar dari masing-masing box untuk bulan Januari hingga Desember terlihat sama sehingga dapat dikatakan varians data homogen.

## 2. Skenario 2

Pada skenario 2, simulasi dilakukan dengan membangkitkan komponen untuk pola tren (Persamaan 4.2), komponen untuk pola musiman dalam bentuk dummy bulan yang bersifat homogen (Persamaan 4.3) dan komponen variasi kalender saat hari raya Idul Fitri maupun satu bulan sebelum hari raya Idul Fitri (Persamaan 4.4), dengan residual dari regresi *time series* yang mengikuti model nonlinear (Persamaan 4.6). Secara visual *time series* plot serta boxplot dari model rekonstruksi pada skenario 2 dapat dilihat pada Gambar 4.5



**Gambar 4.5** Plot *Time Series* pada Skenario 2 (a) dan Boxplot (b)

Pola data pada skenario kedua Gambar 4.5 (a) dan (b) memiliki pola data yang hampir sama dengan Gambar 4.4 (a) dan (b). Adanya pola nonlinear pada residual mengakibatkan sulitnya identifikasi pola data, sehingga perlu dilakukan uji linearitas untuk mengetahui apakah data berpola linear atau nonlinear.

## 3. Skenario 3

Pada skenario ketiga dilakukan simulasi dengan membangkitkan komponen pola tren, komponen pola musiman, dan komponen pola variasi kalender yang memuat variabel *dummy* saat hari raya Idul Fitri dan sebelum hari raya Idul Fitri dimana residual dari proses ini mengikuti model nonlinear. Dalam membangkitkan data dengan pola musiman untuk masing-masing bulan pada data yang memiliki varians data heterogen dapat dilakukan dengan membangkitkan




data yang berdistribusi *uniform*. Berikut adalah rentang nilai yang digunakan untuk membangkitkan data pada masing-masing bulan:

**Tabel 4.1** Rentang Nilai untuk Pola Musiman yang Bersifat Heterogen

Bulan	Distribusi	Bulan	Distribusi
Januari	U(2,12)	Juli	U(2,13)
Februari	U(8,13)	Agustus	U(2,16)
Maret	U(7,15)	September	U(1,10)
April	U(4,16)	Oktober	U(1,8)
Mei	U(2,14)	November	U(2,15)
Juni	U(1,10)	Desember	U(2,17)

Secara visual plot *time series* serta boxplot dari model rekonstruksi pada skenario 3 dapat dilihat pada Gambar 4.6




**Gambar 4.6** Plot *Time Series* pada Skenario 3 (a) dan Boxplot (b)

Berdasarkan Gambar 4.6 (a), data simulasi tertinggi pada bulan Agustus 2012 yaitu bulan pada saat terjadinya Idul Fitri. Berdasarkan Gambar 4.6 (a), boxplot yang terbentuk terlihat lebar dari masing-masing box untuk bulan Januari hingga Desember berbeda. Hal ini menunjukkan bahwa varians data heterogen.

#### 4. Skenario 4

Simulasi pada skenario keempat hampir sama dengan skenario ketiga namun perbedaannya terletak pada residual. Residual dari proses regresi *time series* pada skenario keempat mengikuti model nonlinear pada persamaan (4.6). dalam membangkitkan data dengan pola musiman untuk masing-masing bulan pada data

yang memiliki varians heterogen, dapat dilakukan dengan membangkitkan data yang berdistribusi *uniform*. Rentang yang digunakan untuk membangkitkan data masing-masing bulan sama dengan ketentuan pada Tabel 4.1. Secara visual plot *time series* serta *boxplot* dari model rekonstruksi pada skenario 4 dapat dilihat pada Gambar 4.7



**Gambar 4.7** Plot *Time Series* pada Skenario 4 (a) dan Boxplot (b)

Berdasarkan Gambar 4.7 (a) pola data skenario 4 memiliki pola yang hampir sama dengan Gambar 4.6 (a). *Boxplot* yang terbentuk pada Gambar 4.7 (b) terlihat bahwa lebar dari masing-masing box sangat berbeda. Hal ini menunjukkan bahwa terdapat perbedaan variansi untuk setiap bulannya.

#### 4.1.2 Hasil Simulasi

Setelah memperoleh data bangkitan dari masing-masing skenario pada tahap pertama, langkah selanjutnya adalah memodelkan data yang diperoleh dari masing-masing skenario dengan model ARIMAX, *hybrid* ARIMAX-QR dan *hybrid* QRNN. Berikut akan dijelaskan hasil simulasi dari masing-masing skenario:

##### 1. Skenario 1

Pada skenario 1, simulasi untuk komponen pola tren, komponen untuk pola musiman dalam bentuk *dummy* bulan yang bersifat homogen dan komponen untuk variasi kalender saat hari raya Idul Fitri maupun satu bulan sebelum hari raya Idul Fitri, dimana residual dari model regresi *time series* mengikuti model linear. Pada skenario 1 dilakukan pemodelan menggunakan ARIMAX, *hybrid* ARIMAX-QR dan *hybrid* QRNN pada replikasi 1

Pemodelan pertama yang dilakukan adalah ARIMAX. Tahap awal pembentukan model ARIMAX mengacu pada pemodelan regresi *time series*. Tahapan selanjutnya adalah melakukan estimasi parameter dari model dugaan regresi *time series*. Hasil estimasi parameter dari skenario 1 replikasi 1 dapat dilihat pada Tabel 4.2 berikut:

**Tabel 4.2** Estimasi Parameter Regresi *Time Series* Skenario 1 Replikasi 1

Variabel	Estimasi	t	P-value
$T$	7,300	99,096	0,000
$M_{1,t}$	10,570	16,987	0,000
$M_{2,t}$	12,230	24,522	0,000
$M_{3,t}$	10,640	28,274	0,000
$M_{4,t}$	7,641	24,537	0,000
$M_{5,t}$	6,199	17,559	0,000
$M_{6,t}$	5,209	13,940	0,000
$M_{7,t}$	3,555	11,130	0,000
$M_{8,t}$	1,723	7,559	0,000
$M_{9,t}$	3,116	3,569	0,000
$M_{10,t}$	4,822	6,394	0,000
$M_{11,t}$	6,085	10,512	0,000
$M_{12,t}$	7,186	13,666	0,000
$V_{1,t}$	15,600	7,427	0,000
$V_{2,t}$	26,390	19,718	0,000
$V_{3,t}$	34,470	33,047	0,000
$V_{4,t}$	20,020	43,608	0,000
$V_{1,t-1}$	21,190	20,566	0,000
$V_{2,t-1}$	12,100	26,679	0,000
$V_{3,t-1}$	8,785	15,250	0,000
$V_{4,t-1}$	7,300	11,150	0,000

Berdasarkan Tabel 4.2 seluruh parameter telah signifikan karena *p-value* kurang dari (0,05). Selanjutnya residual dari proses regresi *time series* dicek

apakah sudah memenuhi asumsi *white noise* dan berdistribusi normal. Berikut hasil pengujian *Ljung Box* dan *Kolmogorov smirnov* dari residual proses regresi *time series* pada skenario 1 replikasi 1.

**Tabel 4.3** Hasil Uji *White Noise* dan Normalitas pada Residual Skenario 1

Uji <i>White noise</i>				Uji Normalitas
Lag	$\chi^2$	Df	<i>P-value</i>	<i>P-value</i>
6	136,910	6	0,000	0,843
12	151,290	12	0,000	
18	153,060	18	0,000	
24	153,430	24	0,000	
36	174,690	36	0,000	

Berdasarkan Tabel 4.3 residual belum memenuhi asumsi *white noise* karena semua *p-value* kurang dari (0,05) hingga lag ke-36 serta sudah memenuhi asumsi residual berdistribusi normal karena *p-value* lebih dari (0,05). Residual belum memenuhi asumsi *white noise* sehingga residual dimodelkan menggunakan ARIMA. Residual dari proses regresi *time series* telah memenuhi kriteria residual stasioner dalam mean maupun varians, sehingga residual dimodelkan dengan AR(1) karena pada plot ACF *dies down* dan PACF *cut off* pada lag 1. Berikut adalah hasil estimasi parameter pada model AR(1):

**Tabel 4.4** Estimasi Parameter dan Uji Signifikansi Parameter Skenario 1

Model	Parameter	Estimasi	t-value	<i>P-value</i>
ARIMA (1,0,0)	$w_1$	0,667	10,286	0,000

Berdasarkan Tabel 4.4 seluruh parameter telah signifikan karena *p-value* kurang dari (0,05). Selanjutnya dilakukan pengecekan residual dari proses

regresi *time series* apakah sudah memenuhi asumsi *white noise* dan distribusi normal. Berikut hasil pengujian *Ljung Box* dan *Kolmogorov Smirnov*

**Tabel 4.5** Hasil Uji *White Noise* dan Normalitas Residual ARIMA Skenario 1

Uji <i>White Noise</i>				Uji Normalitas
Lag	$\chi^2$	Df	<i>P-value</i>	<i>P-value</i>
6	4,524	6	0,606	0,973
12	11,457	12	0,490	
18	22,439	18	0,213	
24	29,756	24	0,193	
36	39,485	36	0,317	

Residual telah memenuhi asumsi *white noise* karena semua *p-value* lebih dari (0,05) hingga lag ke-36 serta sudah memenuhi asumsi residual berdistribusi normal karena *p-value* lebih dari (0,05). Selanjutnya dilakukan uji Lagrange Multiplier (LM) untuk mendeteksi apakah varians residual homogen atau heterogen. Pengujian LM menghasilkan varians residual homogen karena *p-value* lebih besar dari (0,05) sehingga dapat dikatakan model ARIMAX skenario 1 replikasi 1 bersifat homokedastisitas. Persamaan untuk model ARIMAX (1,0,0) pada skenario 1 replikasi 1 adalah sebagai berikut:

$$\begin{aligned}
 Y_{11t} = & 0,302t + 7,300M_1 + 10,570M_2 + 12,230M_3 + 10,640M_4 + \\
 & 7,641M_5 + 6,199M_6 + 5,209M_7 + 3,555M_8 + 1,723M_9 + \\
 & 3,116M_{10} + 4,822M_{11} + 6,085M_{12} + 7,186V_{1,t} + \\
 & 15,600V_{2,t} + 26,390V_{3,t} + 34,470V_{4,t} + 20,020V_{1,t+1} + \\
 & 21,190V_{2,t+1} + 12,100V_{3,t+1} + 8,785V_{4,t+1} + 0,667Y_{11,t-1} + a_t
 \end{aligned} \tag{4.7}$$

Pemodelan ARIMAX pada skenario 1 dilakukan sebanyak 5 kali dengan mengubah bangkitan  $a_t$  untuk komponen residual. Pemodelan ARIMAX pada skenario 1 untuk masing-masing replikasi diberi perlakuan yang sama.

Selanjutnya diperoleh nilai RMSE dari masing-masing replikasi yang dapat dilihat pada Tabel 4.6 berikut:

**Tabel 4.6** Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 1

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	0,879	2,653	0,600	2,261
2	0,951	1,880	0,674	1,403
3	1,057	1,342	0,673	1,147
4	1,364	<b>0,949</b>	0,627	0,999
5	0,976	2,119	0,697	1,155

Berdasarkan Tabel 4.6 diperoleh nilai RMSE yang berbeda untuk setiap replikasi yang dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  pada komponen residual. Nilai RMSE terkecil pada skenario 1 terletak pada replikasi 3 untuk data *in-sample* dan pada replikasi 4 untuk data *out-sample*. Nilai MdAE terkecil terletak pada replikasi 4 untuk data data *in-sample* dan pada replikasi 1 untuk data *out-sample*. Berdasarkan hasil ini dapat dikatakan bahwa besar kecilnya replikasi tidak mempengaruhi besar kecilnya nilai RMSE maupun MdAE.

Selanjutnya dilakukan pemodelan menggunakan ARIMAX-QR pada data simulasi skenario 1. Pemodelan ARIMAX-QR ini mengikuti metode yang diperkenalkan oleh Arunraj dan Ahrens (2015). Metode ini menggunakan nilai ramalan metode ARIMAX dari data sebagai prediktor untuk regresi kuantil. Hasil estimasi parameter model ARIMAX-QR dari skenario 1 replikasi 1 dapat dilihat pada Tabel 4.7 berikut:

**Tabel 4.7** Hasil Estimasi Parameter dan Uji signifikansi Parameter Model ARIMAX-QR Skenario 1

Kuantil	Estimasi	T	<i>P-value</i>
0,025	0,926	293,834	0,000
0,500	1,000	310,284	0,000
0,975	1,068	357,382	0,000

Berdasarkan Tabel 4.7 seluruh parameter telah signifikan karena *p-value* kurang dari (0,05). Selanjutnya dilakukan uji Lagrange Multiplier (LM) untuk mendeteksi apakah varians residual homogen atau heterogen. Pengujian LM menghasilkan varians residual homogen karena *p-value* lebih besar dari (0,05) sehingga dapat dikatakan model ARIMAX-QR skenario 1 replikasi 1 bersifat homokedastisitas. Persamaan untuk model ARIMAX-QR pada skenario 1 replikasi 1 adalah sebagai berikut:

$$\begin{aligned}
 Y_{11t}(2,5\%) &= 0,926\hat{Z}_{11t} \\
 Y_{11t}(50\%) &= 1,000\hat{Z}_{11t} \\
 Y_{11t}(97,5\%) &= 1,068\hat{Z}_{11t}
 \end{aligned} \tag{4.8}$$

Pada pemodelan diatas  $\hat{Z}_{11t}$  merupakan nilai prediksi dari pemodelan ARIMAX. Pemodelan ARIMAX-QR pada skenario 1 dilakukan sebanyak 5 kali dengan mengubah bangkitan  $a_t$  untuk komponen residual, dimana nilai RMSE yang diperoleh dari masing-masing replikasi dapat dilihat pada Tabel 4.8 berikut:

**Tabel 4.8** Nilai RMSE untuk Pemodelan ARIMAX-QR pada Skenario 1

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	1,295	1,787	1,542	2,926
2	1,278	1,670	1,422	2,617
3	1,387	1,758	1,739	2,801
4	1,632	<b>1,284</b>	1,464	2,501
5	1,367	1,815	1,626	3,202

Berdasarkan Tabel 4.8 diperoleh nilai RMSE yang berbeda untuk setiap replikasi yang dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  pada komponen residual. Nilai RMSE terkecil pada skenario 1 terletak pada replikasi 3 untuk data *in-sample* dan pada replikasi 4 untuk data *out-sample*. Nilai MdAE terkecil terletak pada replikasi 4 untuk data *in-sample* dan pada replikasi 1 untuk data *out-sample*. Berdasarkan hasil ini dapat dikatakan bahwa besar kecilnya replikasi tidak mempengaruhi besar kecilnya nilai RMSE maupun MdAE.

Selanjutnya dilakukan pemodelan menggunakan model *hybrid* QRNN pada data simulasi skenario 1. Model *hybrid* QRNN mengacu pada pemodelan *Neural Network* yang memuat  $n$  input dan dikoneksikan pada  $m$  unit dalam *hidden layer*. Tahap awal pembentukan model *hybrid* QRNN adalah mengacu pada pemodelan regresi *time series*. Selanjutnya dengan menggunakan residual regresi *time series* dilakukan identifikasi lag PACF yang signifikan untuk digunakan sebagai input pada pembentukan model QRNN. Lag PACF yang signifikan pada skenario 1 adalah lag 1 yang merupakan model AR (1), sehingga input yang digunakan pada QRNN adalah 1 input ( $Y_{t-1}$ ) dengan variasi neuron pada *hidden layer*. Nilai RMSE dari pemodelan menggunakan *hybrid* QRNN pada skenario 1 replikasi 1 ditampilkan pada Tabel 4.9:

**Tabel 4.9** Nilai RMSE untuk Pemodelan *Hybrid* QRNN pada Skenario 1

Jumlah Neuron pada Hidden Layer	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	0,877	2,612	0,589	2,255
2	0,834	2,228	0,616	1,668
3	0,854	2,544	0,632	2,147
4	0,832	2,302	0,573	1,828
5	0,803	2,119	0,521	1,548
10	0,798	2,068	0,512	1,682
15	0,803	2,117	0,457	<b>1,540</b>



Berdasarkan Tabel 4.9 diperoleh nilai RMSE dan MdAE *out-sample* terkecil dengan menggunakan 1 input dan 3 neuron pada *hidden layer*. Setelah didapatkan model terbaik maka dilakukan uji *lagrange Multiplier* (LM) untuk mendeteksi homogenitas varians residual model *hybrid* QRNN. Uji LM menghasilkan varians residual homogen dimana *p-value* yang diperoleh lebih besar dari dari (0,05) sehingga dapat dikatakan model *hybrid* QRNN skenario 1 replikasi 1 bersifat homokedastisitas. Persamaan untuk model *hybrid* QRNN pada skenario 1 replikasi 1 adalah sebagai berikut:

$$\begin{aligned} Y_{11t}(2,5\%) &= -1,510 - 0,926 \tanh(26,860 - 6,215 \hat{Z}_{11t}) \\ Y_{11t}(50\%) &= -1,510 - 0,926 \tanh(26,860 - 6,215 \hat{Z}_{11t}) \\ Y_{11t}(97,5\%) &= -1,510 - 0,926 \tanh(26,860 - 6,215 \hat{Z}_{11t}) \end{aligned} \quad (4.9)$$

Pemodelan *hybrid* QRNN pada skenario 1 dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  untuk komponen residual. Nilai RMSE dari model *hybrid* QRNN terbaik untuk masing-masing replikasi ditampilkan pada Tabel 4.10 :

**Tabel 4.10** Nilai RMSE Replikasi Pemodelan *Hybrid* QRNN Skenario 1

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	0,803	2,119	0,521	1,548
2	0,883	1,672	0,612	<b>0,909</b>
3	1,044	1,473	0,637	1,151
4	0,956	1,452	0,637	1,268
5	0,971	2,166	0,588	1,092

Pada keseluruhan replikasi skenario 1, input yang digunakan adalah nilai prediksi dari model ARIMAX. Berdasarkan Tabel 4.10 diperoleh nilai RMSE terkecil untuk skenario 1 adalah pada replikasi 5. Dengan demikian model terbaik pada skenario 1 adalah pada replikasi 2 dengan 1 neuron pada *hidden layer*. Selanjutnya akan dilihat metode mana yang sesuai untuk skenario pertama dari

ketiga metode yang dijelaskan. Untuk melihat metode mana yang terbaik digunakan nilai *out-sample* terkecil pada masing-masing replikasi.

**Tabel 4.11** Perbandingan RMSE untuk Skenario 1

Model	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
ARIMAX	1,045	1,789	0,654	1,393
ARIMAX-QR	1,392	1,663	1,559	2,809
QRNN	0,931	1,776	0,599	1,194

Pemodelan yang dilakukan dengan ketiga metode menghasilkan nilai RMSE dan MdAE yang bervariasi. Kriteria RMSE memberikan nilai *out-sample* terkecil pada metode ARIMAX-QR sedangkan kriteria MdAE memberikan nilai *out-sample* terkecil pada metode QRNN. Untuk memodelkan data yang mengandung varians homogen dan memiliki hubungan linear, model terbaik yang digunakan adalah model ARIMAX-QR.

## 2. Skenario 2

Pada skenario 2, dilakukan simulasi untuk data yang mengandung komponen untuk pola tren, komponen untuk pola musiman yang bersifat homogen dan komponen untuk variasi kalender untuk saat hari raya Idul Fitri dengan residual mengikuti model nonlinear seperti yang ditunjukkan pada Gambar 4.3 (b). Pada skenario 2 dilakukan pemodelan menggunakan metode ARIMAX, ARIMAX-QR dan QRNN. Tahapan dalam melakukan pemodelan dengan ketiga metode tersebut hampir sama dengan skenario 1.

Pemodelan pertama yang dilakukan adalah ARIMAX. Tahap awal pemebentukan model ARIMAX mengacu pada pemodelan regresi *time series*. Tahapan selanjutnya adalah melakukan estimasi parameter dari model dugaan regresi *time series*. Hasil estimasi parameter dari skenario 2 replikasi 1 dapat dilihat pada Lampiran 1E. Selanjutnya akan dilakukan pengecekan residual regresi *time series*. Model ARIMAX yang diperoleh skenario 2 replikasi 1 adalah ARIMAX (1,0,0) seperti yang tertulis pada Persamaan 4.10:

$$\begin{aligned}
Y_{21t} = & 0,085t + 4,171M_1 + 4,750M_2 + 5,459M_3 + 5,144M_4 + 4,024M_5 + \\
& 2,968M_6 - 0,265M_7 - 1,252M_8 - 1,723M_9 - 1,099M_{10} - 0,065M_{11} + \\
& 1,350M_{12} + 1,727V_{1,t} + 0,265V_{2,t} + 1,866V_{3,t} - 0,944V_{4,t} - 2,546V_{1,t+1} + \\
& 1,772V_{2,t+1} + 2,051V_{3,t+1} + 1,265V_{4,t+1} + 0,289Y_{21,t-1} + a_t
\end{aligned} \quad (4.10)$$

Pemodelan ARIMAX pada skenario 2 dilakukan sebanyak 5 kali dengan mengubah bangkitan  $a_t$  untuk komponen residual. Pemodelan ARIMAX pada skenario 2 untuk masing-masing replikasi diberi perlakuan yang sama. Selanjutnya diperoleh nilai RMSE dari masing-masing replikasi yang dapat dilihat pada Tabel 4.12 berikut:

**Tabel 4.12** Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 2

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,828	<b>3,190</b>	2,084	2,334
2	3,075	3,687	2,272	2,641
3	3,059	3,575	2,038	<b>2,272</b>
4	2,822	4,025	2,257	2,547
5	2,676	3,556	1,894	2,970

Berdasarkan Tabel 4.12 diperoleh nilai RMSE yang berbeda untuk setiap replikasi yang dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  pada komponen residual. Nilai RMSE terkecil pada skenario 2 terletak pada replikasi 1 untuk data *out-sample*. Nilai MdAE terkecil terletak pada replikasi 3 untuk data *out-sample*. Berdasarkan hasil ini dapat dikatakan bahwa besar kecilnya replikasi tidak mempengaruhi besar kecilnya nilai RMSE maupun MdAE.

Selanjutnya dilakukan pemodelan menggunakan ARIMAX-QR pada data simulasi skenario 2. Hasil estimasi parameter model ARIMAX-QR dari skenario 2 replikasi 1 dapat dilihat pada Tabel 4.13 berikut:

**Tabel 4.13** Hasil Estimasi Parameter dan Uji signifikansi Parameter Model ARIMAX-QR Skenario 2

Kuantil	Estimasi	t	<i>P-value</i>
0,025	0,184	4,999	0,000
0,500	1,007	19,793	0,000
0,975	1,707	25,269	0,000

Berdasarkan Tabel 4.13 seluruh parameter telah signifikan karena *p-value* kurang dari (0,05). Selanjutnya dilakukan uji Lagrange Multiplier (LM) untuk mendeteksi apakah varians residual homogen atau heterogen. Pengujian LM menghasilkan varians residual yang belum homogen karena ada *p-value* lebih kurang dari (0,05) sehingga dapat dikatakan model ARIMAX-QR skenario 2 replikasi 1 bersifat heterokedastisitas. Persamaan untuk model ARIMAX-QR pada skenario 2 replikasi 1 adalah sebagai berikut:

$$\begin{aligned}
 Y_{21t}(2,5\%) &= 0,184\hat{Z}_{21t} \\
 Y_{21t}(50\%) &= 1,007\hat{Z}_{21t} \\
 Y_{21t}(97,5\%) &= 1,707\hat{Z}_{21t}
 \end{aligned}
 \tag{4.11}$$

Pada pemodelan diatas  $\hat{Z}_{21t}$  merupakan nilai prediksi dari pemodelan ARIMAX. Pemodelan ARIMAX-QR pada skenario 2 dilakukan sebanyak 5 kali dengan mengubah bangkitan  $a_t$  untuk komponen residual, dimana nilai RMSE yang diperoleh dari masing-masing replikasi dapat dilihat pada Tabel 4.14 berikut:

**Tabel 4.14** Nilai RMSE untuk Pemodelan ARIMAX-QR pada Skenario 2

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,236	2,820	4,426	8,049
2	2,194	<b>2,776</b>	4,059	8,013
3	2,133	2,865	3,818	<b>7,375</b>
4	2,141	2,890	3,858	8,921
5	2,116	2,780	3,595	7,671

Berdasarkan Tabel 4.14 diperoleh nilai RMSE yang berbeda untuk setiap replikasi yang dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  pada komponen residual. Nilai RMSE terkecil pada skenario 2 terletak pada replikasi 2 untuk data *out-sample*. Nilai MdAE terkecil terletak pada replikasi 3 untuk data *out-sample*. Berdasarkan hasil ini dapat dikatakan bahwa besar kecilnya replikasi tidak mempengaruhi besar kecilnya nilai RMSE maupun MdAE.

Selanjutnya dilakukan pemodelan menggunakan model *hybrid* QRNN pada data simulasi skenario 2. Tahap awal pembentukan model *hybrid* QRNN adalah mengacu pada pemodelan regresi *time series*. Selanjutnya dengan menggunakan residual regresi *time series* dilakukan identifikasi lag PACF yang signifikan untuk digunakan sebagai input pada pembentukan model QRNN. Lag PACF yang signifikan pada skenario 2 adalah lag 1 yang merupakan model AR (1), sehingga input yang digunakan pada QRNN adalah 1 input ( $Y_{t-1}$ ) dengan variasi neuron pada *hidden layer*. Nilai RMSE dari pemodelan menggunakan *hybrid* QRNN pada skenario 2 replikasi 1 ditampilkan pada Tabel 4.15:

**Tabel 4.15** Nilai RMSE untuk Pemodelan *Hybrid* QRNN pada Skenario 2

Jumlah Neuron pada <i>Hidden Layer</i>	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,897	2,612	2,120	2,382
2	2,891	2,228	2,040	2,395
3	2,907	2,544	2,002	2,599
4	2,903	2,302	2,008	2,471
5	2,863	2,119	2,002	2,802
10	2,907	<b>2,068</b>	2,076	2,599
15	2,856	2,117	1,665	2,713

Berdasarkan tabel 4.15 diperoleh nilai RMSE dan MdAE *out-sample* terkecil dengan menggunakan 1 input dan 3 neuron pada *hidden layer*. Setelah didapatkan model terbaik maka dilakukan uji *lagrange Multiplier* (LM) untuk

mendeteksi homogenitas varians residual model *hybrid* QRNN. Uji LM menghasilkan varians residual homogen dimana *p-value* yang diperoleh lebih besar dari dari (0,05) sehingga dapat dikatakan model *hybrid* QRNN skenario 2 replikasi 1 bersifat homokedastisitas. Persamaan untuk model *hybrid* QRNN pada skenario 1 replikasi 1 adalah sebagai berikut:

$$\begin{aligned} Y_{21t}(2,5\%) &= -17,160-18,828 \tanh(-18,828+0,470\hat{Z}_{21t}) + a_t \\ Y_{21t}(50\%) &= 4,070-10,071 \tanh(12,793+7,662\hat{Z}_{21t}) + a_t \\ Y_{21t}(97,5\%) &= 6,733-4,797 \tanh(6,945-0,077\hat{Z}_{21t}) + a_t \end{aligned} \quad (4.12)$$

Pada pemodelan diatas  $\hat{Z}_{21t}$  merupakan nilai prediksi dari pemodelan ARIMAX. Pemodelan *hybrid* QRNN pada skenario 2 dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  untuk komponen residual. Nilai RMSE dari model *hybrid* QRNN terbaik untuk masing-masing replikasi ditampilkan pada Tabel 4.16 :

**Tabel 4.16** Nilai RMSE untuk Pemodelan *Hybrid* QRNN Skenario 2

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,907	2,068	2,076	2,599
2	2,894	3,578	2,014	3,027
3	3,004	3,012	1,903	<b>1,376</b>
4	2,867	3,998	2,230	2,126
5	2,670	3,207	1,830	2,851

Pada keseluruhan replikasi skenario 2, input yang digunakan adalah nilai prediksi dari model ARIMAX. Berdasarkan Tabel 4.16 diperoleh nilai RMSE terkecil untuk skenario 2 adalah pada replikasi 3. Dengan demikian model terbaik pada skenario 2 adalah pada replikasi 3 dengan 15 neuron pada *hidden layer*. Selanjutnya akan dilihat metode mana yang sesuai untuk skenario pertama dari ketiga metode yang dijelaskan. Untuk melihat metode mana yang terbaik digunakan nilai out-sample terkecil pada masing-masing replikasi.

**Tabel 4.17** Perbandingan RMSE untuk Skenario 2

Model	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
ARIMAX	2,892	3,607	2,109	2,553
ARIMAX-QR	2,164	2,826	3,951	8,006
QRNN	2,8684	3,173	2,011	2,396

Pemodelan yang dilakukan dengan ketiga metode menghasilkan nilai RMSE dan MdAE yang bervariasi. Kriteria RMSE memberikan nilai *out-sample* terkecil pada metode ARIMAX-QR sedangkan kriteria MdAE memberikan nilai *out-sample* terkecil pada metode QRNN. Untuk memodelkan data yang mengandung varians homogen dan memiliki hubungan nonlinear, model terbaik yang digunakan adalah model QRNN.

### 3. Skenario 3

Pada skenario 3, dilakukan simulasi dengan membangkitkan data yang mengandung komponen untuk pola tren, komponen untuk pola musiman dalam bentuk *dummy* bulan yang bersifat heterogen dan komponen untuk variasi kalender untuk saat hari raya Idul Fitri maupun satu bulan sebelum hari raya Idul Fitri dengan residual mengikuti model linear. Pada skenario 3 dilakukan pemodelan menggunakan metode ARIMAX, ARIMAX-QR dan QRNN. Tahapan dalam melakukan pemodelan dengan ketiga metode tersebut hampir sama dengan skenario sebelumnya.

Pemodelan pertama yang dilakukan adalah ARIMAX. Tahap awal pembentukan model ARIMAX mengacu pada pemodelan regresi *time series*. Tahapan selanjutnya adalah melakukan estimasi parameter dari model dugaan regresi *time series*. Hasil estimasi parameter dari skenario 3 replikasi 1 dapat dilihat pada Lampiran IC. Selanjutnya akan dilakukan pengecekan residual regresi *time series*. Jika residual belum memenuhi asumsi *white noise* maka residual tersebut akan dimodelkan menggunakan metode ARIMA. Residual regresi *time series* signifikan pada lag 1 sehingga diperoleh model AR(1). Model ARIMAX yang diperoleh skenario 2 replikasi 1 adalah ARIMAX (1,0,0) seperti yang tertulis pada Persamaan 4.13:

$$\begin{aligned}
Y_{31t} = & 0,089t + 6,437M_1 + 11,496M_2 + 10,714M_3 + 10,447M_4 + \\
& 10,541M_5 + 5,190M_6 + 9,852M_7 + 13,019M_8 + 7,3305M_9 + \\
& 6,109M_{10} + 10,865M_{11} + 11,210M_{12} + 0,950V_{1,t} + 0,274V_{2,t} + \\
& 1,226V_{3,t} + 2,483V_{4,t} + 2,838V_{1,t+1} - 0,830V_{2,t+1} + \\
& 0,004V_{3,t+1} + 2,962V_{4,t+1} + 0,128Y_{31,t-1} + a_t
\end{aligned} \tag{4.13}$$

Pemodelan ARIMAX pada skenario 3 dilakukan sebanyak 5 kali dengan mengubah bangkitan  $a_t$  untuk komponen residual. Pemodelan ARIMAX pada skenario 3 untuk masing-masing replikasi diberi perlakuan yang sama. Selanjutnya diperoleh nilai RMSE dari masing-masing replikasi yang dapat dilihat pada Tabel 4.18 berikut:

**Tabel 4.18** Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 3

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,574	3,696	1,872	2,801
2	2,652	2,945	1,886	1,907
3	2,693	3,595	1,685	3,507
4	2,743	<b>3,224</b>	1,827	2,973
5	2,680	3,099	1,756	2,905

Berdasarkan Tabel 4.18 diperoleh nilai RMSE yang berbeda untuk setiap replikasi yang dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  pada komponen residual. Nilai RMSE terkecil pada skenario 3 terletak pada replikasi 3 untuk data *in-sample* dan pada replikasi 4 untuk data *out-sample*. Nilai MdAE terkecil terletak pada replikasi 4 untuk data data *in-sample* dan pada replikasi 1 untuk data *out-sample*. Berdasarkan hasil ini dapat dikatakan bahwa besar kecilnya replikasi tidak mempengaruhi besar kecilnya nilai RMSE maupun MdAE.

Selanjutnya dilakukan pemodelan menggunakan ARIMAX-QR pada data simulasi skenario 3. Hasil estimasi parameter model ARIMAX-QR dari skenario 3 replikasi 1 dapat dilihat pada Tabel 4.19 berikut:



**Tabel 4.19** Hasil Estimasi Parameter dan Uji signifikansi Parameter Model ARIMAX-QR Skenario 3

Kuantil	Estimasi	t	<i>P-value</i>
0,025	0,709	83,372	0,000
0,500	1,000	57,563	0,000
0,975	1,334	48,870	0,000

Berdasarkan Tabel 4.19 seluruh parameter telah signifikan karena *p-value* kurang dari (0,05). Selanjutnya dilakukan uji Lagrange Multiplier (LM) untuk mendeteksi apakah varians residual homogen atau heterogen. Pengujian LM menghasilkan varians residual yang homogen karena *p-value* lebih dari (0,05) sehingga dapat dikatakan model ARIMAX-QR skenario 3 replikasi 1 bersifat homogen. Persamaan untuk model ARIMAX-QR pada skenario 3 replikasi 1 adalah sebagai berikut:

$$\begin{aligned}
 Y_{31t}(2,5\%) &= 0,709\hat{Z}_{31t} \\
 Y_{31t}(50\%) &= 1,000\hat{Z}_{31t} \\
 Y_{31t}(97,5\%) &= 1,334\hat{Z}_{31t}
 \end{aligned}
 \tag{4.14}$$

Pemodelan ARIMAX-QR pada skenario 3 dilakukan sebanyak 5 kali dengan mengubah bangkitan  $a_t$  untuk komponen residual, dimana nilai RMSE yang diperoleh dari masing-masing replikasi dapat dilihat pada Tabel 4.20 :

**Tabel 4.20** Nilai RMSE untuk Pemodelan ARIMAX-QR pada Skenario 3

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,037	2,411	3,765	4,980
2	2,016	2,325	3,621	5,617
3	2,122	2,489	4,191	5,875
4	2,132	<b>2,469</b>	4,242	5,207
5	2,119	2,474	3,951	5,695

Berdasarkan Tabel 4.20 diperoleh nilai RMSE yang berbeda untuk setiap replikasi yang dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  pada komponen residual. Nilai RMSE terkecil pada skenario 3 terletak pada replikasi 3 untuk data *out-sample*. Nilai MdAE terkecil terletak pada replikasi 4 untuk data *out-sample*. Berdasarkan hasil ini dapat dikatakan bahwa besar kecilnya replikasi tidak mempengaruhi besar kecilnya nilai RMSE maupun MdAE.

Selanjutnya dilakukan pemodelan menggunakan model *hybrid* QRNN pada data simulasi skenario 3. Tahap awal pembentukan model *hybrid* QRNN adalah mengacu pada pemodelan regresi *time series*. Selanjutnya dengan menggunakan residual regresi *time series* dilakukan identifikasi lag PACF yang signifikan untuk digunakan sebagai input pada pembentukan model QRNN. Lag PACF yang signifikan pada skenario 3 adalah lag 1 yang merupakan model AR (1), sehingga input yang digunakan pada QRNN adalah 1 input ( $Y_{t-1}$ ) dengan variasi neuron pada *hidden layer*. Untuk mendapatkan hasil yang optimal diambil variasi neuron 1,2,3,4,5,10 dan 15. Nilai RMSE dari pemodelan menggunakan *hybrid* QRNN pada skenario 3 replikasi 1 ditampilkan pada Tabel 4.21:

**Tabel 4.21** Nilai RMSE untuk Pemodelan *Hybrid* QRNN pada Skenario 3

Jumlah Neuron pada Hidden Layer	RMSE		MDAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,560	3,592	2,874	<b>2,382</b>
2	2,555	3,583	3,026	2,395
3	2,531	<b>3,542</b>	2,795	2,599
4	2,578	3,448	2,795	2,471
5	2,619	6,998	2,884	2,802
10	2,459	7,034	3,081	2,599
15	2,392	5,670	2,931	2,713

Berdasarkan Tabel 4.21 diperoleh nilai RMSE dan MdAE *out-sample* terkecil dengan menggunakan 1 input dan 1 neuron pada *hidden layer*. Setelah

didapatkan model terbaik maka dilakukan uji *lagrange Multiplier* (LM) untuk mendeteksi homogenitas varians residual model *hybrid QRNN*. Uji LM menghasilkan varians residual homogen dimana *p-value* yang diperoleh lebih besar dari dari (0,05) sehingga dapat dikatakan model *hybrid QRNN* skenario 3 replikasi 1 bersifat homokedastisitas. Persamaan untuk model *hybrid QRNN* pada skenario 1 replikasi 1 adalah sebagai berikut:

$$\begin{aligned} Y_{31t}(2,5\%) &= -9,382 - 9,645 \tanh(4,437 - 0,785\hat{Z}_{31t}) + a_t \\ Y_{31t}(50\%) &= -17,718 + 9,474 \tanh(-29,214 - 5,501\hat{Z}_{31t}) + a_t \\ Y_{31t}(97,5\%) &= -9,796 - 0,553 \tanh(-1,752 - 0,152\hat{Z}_{31t}) + a_t \end{aligned} \quad (4.15)$$

Pada pemodelan diatas  $\hat{Z}_{31t}$  merupakan nilai prediksi dari pemodelan ARIMAX. Pemodelan *hybrid QRNN* pada skenario 3 dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  untuk komponen residual. Nilai RMSE dari model *hybrid QRNN* terbaik untuk masing-masing replikasi ditampilkan pada Tabel 4.22 dimana pada keseluruhan replikasi skenario 3, input yang digunakan adalah nilai prediksi dari model ARIMAX.

**Tabel 4.22** Nilai RMSE untuk Pemodelan *Hybrid QRNN* Skenario 3

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,560	3,592	2,874	2,382
2	2,656	2,866	1,731	<b>1,732</b>
3	2,689	3,511	1,635	3,353
4	2,752	3,076	1,599	2,966
5	2,493	2,594	1,260	2,471

Berdasarkan Tabel 4.22 diperoleh nilai RMSE terkecil untuk skenario 3 adalah pada replikasi 5. Dengan demikian model terbaik pada skenario 3 adalah pada replikasi 2 dengan 1 neuron pada *hidden layer*. Selanjutnya akan dilihat metode mana yang sesuai untuk skenario pertama dari ketiga metode yang dijelaskan. Untuk melihat metode mana yang terbaik digunakan nilai outsample terkecil pada masing-masing replikasi.

**Tabel 4.23** Perbandingan RMSE untuk Skenario 3

Model	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
ARIMAX	2,668	3,312	1,805	2,819
ARIMAX-QR	2,085	2,434	3,954	5,475
QRNN	2,630	3,128	1,820	2,581

Pemodelan yang dilakukan dengan ketiga metode menghasilkan nilai RMSE dan MdAE yang bervariasi. Kriteria RMSE memberikan nilai *out-sample* terkecil pada metode ARIMAX-QR sedangkan kriteria MdAE memberikan nilai *out-sample* terkecil pada metode QRNN. Untuk memodelkan data yang mengandung varians heterogen dan memiliki hubungan linear, model terbaik yang digunakan adalah model ARIMAX-QR.

#### 4. Skenario 4

Pada skenario 4, dilakukan simulasi dengan membangkitkan data yang mengandung komponen untuk pola tren, komponen untuk pola musiman dalam bentuk *dummy* bulan yang bersifat heterogen dan komponen untuk variasi kalender untuk saat hari raya Idul Fitri maupun satu bulan sebelum hari raya Idul Fitri dengan residual mengikuti model nonlinear seperti yang ditunjukkan pada Gambar 4.3 (b). Pada skenario 4 dilakukan pemodelan menggunakan metode ARIMAX, ARIMAX-QR dan QRNN. Tahapan dalam melakukan pemodelan dengan ketiga metode tersebut hampir sama dengan skenario sebelumnya.

Pemodelan pertama yang dilakukan adalah ARIMAX. Tahap awal pembentukan model ARIMAX mengacu pada pemodelan regresi *time series*. Tahapan selanjutnya adalah melakukan estimasi parameter dari model dugaan regresi *time series*. Hasil estimasi parameter dari skenario 4 replikasi 1 dapat dilihat pada Lampiran IG. Selanjutnya akan dilakukan pengecekan residual regresi *time series*. Jika residual belum memenuhi asumsi *white noise* maka residual tersebut akan dimodelkan menggunakan metode ARIMA. Model ARIMAX yang diperoleh skenario 4 replikasi 1 adalah ARIMAX (1,0,0) seperti yang tertulis pada Persamaan 4.16:

$$\begin{aligned}
Y_{41t} = & 0,096t + 6,030M_1 + 12,090M_2 + 9,24M_3 + 9,133M_4 + 9,278M_5 + \\
& 6,217M_6 + 9,811M_7 + 12,62M_8 + 6,336M_9 + 4,487M_{10} + \\
& 10,160M_{11} + 11,320M_{12} + 1,91V_{1,t} + 3,435V_{2,t} + 3,014V_{3,t} + \\
& 5,19V_{4,t} + 4,666V_{1,t+1} + 0,415V_{2,t+1} + \\
& 0,134V_{3,t+1} + 1,878V_{4,t+1} + 0,188Y_{41,t-1} + a_t
\end{aligned} \tag{4.16}$$

Pemodelan ARIMAX pada skenario 4 dilakukan sebanyak 5 kali dengan mengubah bangkitan  $a_t$  untuk komponen residual. Pemodelan ARIMAX pada skenario 4 untuk masing-masing replikasi diberi perlakuan yang sama. Selanjutnya diperoleh nilai RMSE dari masing-masing replikasi yang dapat dilihat pada Tabel 4.24 berikut:

**Tabel 4.24** Nilai RMSE untuk Pemodelan ARIMAX pada Skenario 4

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	3,598	4,071	2,153	4,168
2	4,018	3,960	2,923	2,291
3	2,573	3,047	6,287	9,233
4	3,873	2,998	2,337	2,052
5	4,032	5,379	2,979	4,562

Berdasarkan Tabel 4.24 diperoleh nilai RMSE yang berbeda untuk setiap replikasi yang dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  pada komponen residual. Nilai RMSE terkecil pada skenario 4 terletak pada replikasi 3 untuk data *in-sample* dan pada replikasi 4 untuk data *out-sample*. Nilai MdAE terkecil terletak pada replikasi 4 untuk data data *in-sample* dan pada replikasi 1 untuk data *out-sample*. Berdasarkan hasil ini dapat dikatakan bahwa besar kecilnya replikasi tidak mempengaruhi besar kecilnya nilai RMSE maupun MdAE.

Selanjutnya dilakukan pemodelan menggunakan ARIMAX-QR pada data simulasi skenario 4. Hasil estimasi parameter model ARIMAX-QR dari skenario 4 replikasi 1 dapat dilihat pada Tabel 4.25 berikut:

**Tabel 4.25** Hasil Estimasi Parameter dan Uji signifikansi Parameter Model ARIMAX-QR Skenario 4

Kuantil	Estimasi	T	<i>P-value</i>
0,025	0,535	9,247	0,000
0,500	1,989	58,773	0,000
0,975	1,431	151,930	0,000

Berdasarkan Tabel 4.25 seluruh parameter telah signifikan karena *p-value* kurang dari (0,05). Selanjutnya dilakukan uji Lagrange Multiplier (LM) untuk mendeteksi apakah varians residual homogen atau heterogen. Pengujian LM menghasilkan varians residual yang homogen karena *P-value* lebih dari (0,05) sehingga dapat dikatakan model ARIMAX-QR skenario 4 replikasi 1 bersifat homogen. Persamaan untuk model ARIMAX-QR pada skenario 4 replikasi 1 adalah sebagai berikut:

$$\begin{aligned}
 Y_{41t}(2,5\%) &= 0,535\hat{Z}_{41t} \\
 Y_{41t}(50\%) &= 0,989\hat{Z}_{41t} \\
 Y_{41t}(97,5\%) &= 1,431\hat{Z}_{41t}
 \end{aligned}
 \tag{4.17}$$

Pemodelan ARIMAX-QR pada skenario 4 dilakukan sebanyak 5 kali dengan mengubah bangkitan  $a_t$  untuk komponen residual, dimana nilai RMSE yang diperoleh dari masing-masing replikasi dapat dilihat pada Tabel 4.26 berikut:

**Tabel 4.26** Nilai RMSE untuk Pemodelan ARIMAX-QR pada Skenario 4

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	2,398	2,830	5,423	7,007
2	2,554	2,935	5,773	9,082
3	1,756	<b>2,107</b>	2,434	3,542
4	2,513	2,947	5,876	8,509
5	2,536	3,013	5,608	7,229

Berdasarkan Tabel 4.26 diperoleh nilai RMSE yang berbeda untuk setiap replikasi yang dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  pada komponen residual. Nilai RMSE terkecil pada skenario 4 terletak pada replikasi 3 untuk data *out-sample*. Nilai MdAE terkecil terletak pada replikasi 4 untuk data *out-sample*. Berdasarkan hasil ini dapat dikatakan bahwa besar kecilnya replikasi tidak mempengaruhi besar kecilnya nilai RMSE maupun MdAE.

Selanjutnya dilakukan pemodelan menggunakan model *hybrid* QRNN pada data simulasi skenario 4. Tahap awal pembentukan model *hybrid* QRNN adalah mengacu pada pemodelan regresi *time series*. Selanjutnya dengan menggunakan residual regresi *time series* dilakukan identifikasi lag PACF yang signifikan untuk digunakan sebagai input pada pembentukan model QRNN. Lag PACF yang signifikan pada skenario 4 adalah lag 1 yang merupakan model AR (1), sehingga input yang digunakan pada QRNN adalah 1 input ( $Y_{t-1}$ ) dengan variasi neuron pada *hidden layer*. Variasi neuron yang digunakan untuk mendapatkan hasil yang optimal adalah 1,2,3,4,5,10,15. Nilai RMSE dari pemodelan menggunakan *hybrid* QRNN pada skenario 4 replikasi 1 ditampilkan pada Tabel 4.27:

**Tabel 4.27** Nilai RMSE untuk Pemodelan *Hybrid* QRNN pada Skenario 4

Jumlah Neuron pada Hidden Layer	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	3,614	4,475	2,218	4,507
2	3,614	4,477	2,197	4,507
3	3,550	4,489	1,941	4,543
4	3,591	4,860	1,829	4,474
5	3,533	4,438	1,929	4,246
10	3,353	4,749	1,728	4,799
15	3,342	4,806	1,584	3,303

Berdasarkan Tabel 4.27 diperoleh nilai RMSE dan MdAE *out-sample* terkecil dengan menggunakan 1 input dan 1 neuron pada *hidden layer*. Setelah

didapatkan model terbaik maka dilakukan uji *Lagrange Multiplier* (LM) untuk mendeteksi homogenitas varians residual model *hybrid* QRNN. Uji LM menghasilkan varians residual homogen dimana *P-value* yang diperoleh lebih besar dari dari (0,05) sehingga dapat dikatakan model *hybrid* QRNN skenario 4 replikasi 1 bersifat homokedastisitas. Persamaan untuk model *hybrid* QRNN pada skenario 4 replikasi 1 adalah sebagai berikut:

$$\begin{aligned} Y_{41t}(2,5\%) &= 0,460-8,729 \tanh(0,5 \times (-0,874 - 6,025\hat{Z}_{41t})) + a_t \\ Y_{41t}(50\%) &= 15,736-12,616 \tanh(0,5 \times (5,3164-3,523\hat{Z}_{41t})) + a_t \\ Y_{41t}(97,5\%) &= 15,933 + 6,291 \tanh(0,5 \times (-2,783+7,889\hat{Z}_{41t})) + a_t \end{aligned} \quad (4.18)$$

Pada pemodelan diatas  $\hat{Z}_{41t}$  merupakan nilai prediksi dari pemodelan ARIMAX. Pemodelan *hybrid* QRNN pada skenario 4 dilakukan sebanyak 5 kali dengan mengubah data bangkitan  $a_t$  untuk komponen residual. Nilai RMSE dari model *hybrid* QRNN terbaik untuk masing-masing replikasi ditampilkan pada Tabel 4.28.

**Tabel 4.28** Nilai RMSE untuk Pemodelan *Hybrid* QRNN Skenario 4

Replikasi	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	3,342	4,806	1,584	3,303
2	6,071	6,877	4,403	6,170
3	3,565	4,848	1,743	2,941
4	4,981	2,857	2,700	2,348
5	5,149	4,389	4,039	2,832

Pada keseluruhan replikasi skenario 4, input yang digunakan adalah nilai prediksi dari model ARIMAX. Berdasarkan Tabel 4.27 diperoleh nilai RMSE terkecil untuk skenario 4 adalah pada replikasi 5. Dengan demikian model terbaik pada skenario 4 adalah pada replikasi 4 dengan 2 neuron pada *hidden layer*. Selanjutnya akan dilihat metode mana yang sesuai untuk skenario pertama dari ketiga metode yang dijelaskan. Untuk melihat metode mana yang terbaik digunakan nilai *out-sample* terkecil pada masing-masing replikasi.



**Tabel 4.29** Perbandingan RMSE untuk Skenario 4

Model	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
ARIMAX	3,619	3,891	3,336	4,461
ARIMAX-QR	2,351	2,766	5,023	7,074
QRNN	4,622	4,755	2,894	3,519


Pemodelan yang dilakukan dengan ketiga metode menghasilkan nilai RMSE dan MdAE yang bervariasi. Kriteria RMSE memberikan nilai *out-sample* terkecil pada metode ARIMAX-QR sedangkan kriteria MdAE memberikan nilai *out-sample* terkecil pada metode QRNN. Berdasarkan hasil tersebut untuk memodelkan data yang mengandung varians heterogen dan memiliki hubungan nonlinear, model yang digunakan adalah model QRNN.

Berdasarkan hasil kriteria performansi masing-masing metode diatas pada keempat skenario, dapat dikatakan bahwa model ARIMAX sangat baik digunakan untuk data yang bersifat homogen dan linear, sedangkan model QRNN sangat baik digunakan untuk data yang bersifat heterogen dan nonlinear. Untuk memperdalam pemahaman mengenai kemampuan keempat model diatas dalam peramalan, maka akan diterapkan ketiga model tersebut pada data *inflow* dan *outflow* uang kartal di tingkat Provinsi NTT dan Nasional.

## 4.2 Karakteristik *Inflow* dan *Outflow* Uang Kartal

Pada analisis deskriptif ini, pola yang terbentuk dari data *Inflow* dan *outflow* uang kartal Bank Indonesia di tingkat NTT dan Nasional ditampilkan menggunakan plot *time series* pada Gambar 4.8.

Dari Gambar 4.8, pada umumnya *inflow* uang kartal tertinggi pada bulan Januari setiap tahun sedangkan *outflow* uang kartal tertinggi terjadi pada bulan Desember. Tingginya *inflow* uang kartal di bulan Januari merupakan dampak dari tingginya *outflow* uang kartal pada bulan Desember untuk keperluan Natal dan Tahun baru.




**Gambar 4.8** Time series Plot Inflow-Outflow Uang Kartal Provinsi NTT(a,b) dan Nasional(c,d)

Hal ini menunjukkan adanya pola musiman pada data *inflow* dan *outflow* uang kartal BI NTT dan Nasional. Selain mengalami pola musiman, *outflow* uang kartal cenderung tinggi pada bulan Juni. Kenaikan *outflow* pada bulan Juni dipicu oleh kenaikan kebutuhan uang kartal menghadapi liburan dan pendaftaran sekolah sekaligus didorong oleh pemberian gaji ke-13 bagi PNS di bulan Juni. Adapun kenaikan *outflow* di bulan Desember terkait dengan tingginya permintaan uang oleh masyarakat untuk keperluan menjelang Hari raya Natal dan persiapan Tahun Baru. Pada Gambar 4.8, dapat dilihat juga bahwa pola data *inflow* dan *outflow* mengandung efek variasi kalender, namun untuk efek variasi kalender ini memberikan pola yang berbeda pada *inflow* dan *outflow*. Peningkatan *inflow* dan *outflow* terjadi melalui dua fase yakni jika Idul Fitri terjadi pada pertengahan atau akhir bulan tersebut, *outflow* akan mengalami kenaikan pada bulan terjadinya Idul Fitri, sedangkan jika Idul Fitri terjadi pada awal bulan, maka *outflow* akan mengalami kenaikan pada satu bulan sebelumnya. Jika Idul Fitri

terjadi pada pertengahan atau akhir bulan, *inflow* mengalami kenaikan satu bulan setelah Idul Fitri, sedangkan jika Idul Fitri terjadi pada awal bulan, maka *inflow* mengalami kenaikan pada bulan tersebut.

Pola data *inflow* dan *outflow* di BI NTT pada Gambar 4.8 menunjukkan *inflow* dan *outflow* mengalami perubahan tren, yaitu tren meningkat dari tahun 2005 hingga 2006 kemudian mengalami penurunan yang cukup besar pada tahun 2007. Perubahan pola ini dipicu oleh adanya penerapan kebijakan uji coba setoran bayaran bank yang diberlakukan dari 28 Oktober 2005 dan kemudian diatur dalam ketentuan sesuai dengan surat edaran No.9/37/DPU tanggal 27 Desember 2007 perihal penyetoran dan penarikan uang rupiah oleh Bank Umum di Bank Indonesia. Beberapa hal yang diatur dalam ketentuan ini diantaranya adalah mengenai prosedur penyetoran uang tidak layak edar (UTLE) ke BI, sedangkan uang layak edar (ULE) didistribusikan oleh perbankan melalui transaksi uang kartal antar bank (TUKAB). Namun, BI juga dapat menerima ULE apabila memenuhi persyaratan yang telah ditetapkan, misalnya terjadi kondisi tertentu seperti perbankan mengalami likuiditas uang kartal pecahan tertentu (Bank Indonesia, 2008). Kebijakan ini berlaku secara nasional sejak Desember 2006 di seluruh wilayah KBI, sehingga berdampak pada penurunan terhadap mekanisme penyetoran dan penarikan uang rupiah oleh Bank umum di Bank Indonesia sebagaimana tertuang dalam surat edaran No.13/9/DPU. Perubahan ini tampaknya dapat meningkatkan aliran uang yang melalui BI, sehingga baik *inflow* maupun *outflow* kembali mengalami tren naik pada tahun 2011 hingga tahun 2016. Peningkatan *inflow* dan *outflow* yang tampak tiap tahun ternyata tidak terjadi pada bulan yang sama. Terlihat bahwa terjadi pergeseran bulan satu periode lebih awal. Hal ini mendasari adanya dugaan bahwa terdapat efek variasi kalender yang berpengaruh pada jumlah *inflow* dan *outflow* uang kartal. Hal ini didukung oleh boxplot dalam Gambar 4.9 yang menggambarkan pergerakan *inflow* dan *outflow* bulanan serta efek variasi kalender yang ditimbulkan dari adanya perayaan Idul Fitri.



**Gambar 4.9** Boxplot *Inflow* dan *Outflow* Uang Kartal BI

Gambar 4.9 menunjukkan bahwa rata-rata bulanan tertinggi *inflow* di tingkat NTT dan Nasional terjadi pada bulan Januari, Agustus, September, Oktober, dan November. Pada bulan Januari mempunyai nilai *inflow* yang tinggi dikarenakan bulan tersebut merupakan bulan setelah perayaan Natal dan tahun baru, sehingga masyarakat cenderung menyetorkan uang ke Bank, sementara pada bulan Agustus, September, Oktober, dan November merupakan bulan-bulan yang berkaitan dengan terjadinya hari raya Idul Fitri. Untuk rata-rata bulanan tertinggi *outflow* di kedua tingkatan terjadi bulan Juli, Agustus, September, Oktober, November, dan Desember. Sama halnya dengan pergerakan *inflow*, pada bulan Juli, Agustus, September, Oktober, dan November merupakan bulan-bulan yang berkaitan dengan terjadinya hari raya Idul Fitri. Pada bulan Desember merupakan bulan perayaan Natal dan tahun baru, sehingga masyarakat cenderung menarik uang dari Bank.

Berdasarkan Gambar 4.9 dapat dilihat pula adanya pengaruh hari raya Idul Fitri terhadap pergerakan *inflow* dan *outflow* pada tingkat Nasional dan Provinsi

NTT. Pada penelitian-penelitian sebelumnya sudah dinyatakan bahwa pengaruh hari raya Idul Fitri berkaitan dengan minggu terjadinya hari raya Idul Fitri. Ketika hari raya Idul Fitri jatuh pada minggu pertama, maka rata-rata *inflow* akan mengalami kenaikan pada saat bulan tersebut. Rata-rata *inflow* yang dihasilkan sebesar 60,19 miliar untuk Nasional dan 2,77 miliar untuk Provinsi NTT. Untuk satu bulan setelah hari raya Idul Fitri, rata-rata *inflow* menurun, yaitu 21,37 miliar untuk Nasional dan 1,53 miliar untuk Provinsi NTT. Hal yang serupa juga terjadi apabila hari raya Idul Fitri jatuh pada minggu kedua, yaitu rata-rata *inflow* akan mengalami kenaikan pada saat bulan tersebut. Rata-rata *inflow* yang dihasilkan sebesar 50,49 miliar untuk Nasional dan 2,12 miliar untuk Provinsi NTT. Untuk satu bulan setelah hari raya Idul Fitri, rata-rata *inflow* menurun, yaitu 20,10 miliar untuk Nasional dan 1,54 miliar untuk Provinsi NTT. Apabila hari raya Idul Fitri jatuh pada minggu ketiga, maka rata-rata *inflow* pada saat Idul Fitri sebesar 46,94 untuk tingkat Nasional dan 2,43 untuk provinsi NTT sedangkan untuk satu bulan setelah hari raya Idul Fitri mengalami penurunan sebesar 23,68 untuk tingkat Nasional dan 1,40 untuk Provinsi NTT. Apabila hari raya Idul Fitri jatuh pada minggu keempat, maka rata-rata *inflow* akan mengalami kenaikan pada satu bulan setelah hari raya Idul Fitri. Rata-rata *inflow* yang dihasilkan sebesar 20,2 miliar untuk Nasional dan 1,79 miliar untuk Provinsi NTT serta mengalami peningkatan pada satu bulan setelah hari raya Idul Fitri sebesar 26,12 miliar untuk Nasional dan 2,03 untuk provinsi NTT. Hal tersebut merupakan situasi yang berkebalikan dengan hari raya Idul Fitri yang jatuh pada minggu sebelumnya.

Hal yang sama terjadi pula pada pola pergerakan *outflow* uang kartal BI yang diakibatkan adanya variasi kalender ini. Ketika hari raya Idul Fitri jatuh pada minggu pertama, maka rata-rata *outflow* akan mengalami kenaikan pada satu bulan sebelum hari raya Idul Fitri. Rata-rata *outflow* yang dihasilkan sebesar 81,52 miliar untuk Nasional dan 4,05 miliar untuk Provinsi NTT. Pada saat bulan hari raya Idul Fitri, rata-rata *outflow* menurun, yaitu 18,45 miliar untuk Nasional dan 2,00 miliar untuk Provinsi NTT. Dapat juga disimpulkan bahwa rata-rata *outflow* pada saat bulan hari raya Idul Fitri menurun sangat signifikan rata-rata pada satu bulan sebelum hari raya Idul Fitri, apabila hari raya Idul Fitri jatuh pada minggu pertama. Apabila hari raya Idul Fitri jatuh pada minggu kedua, maka rata-

rata *outflow* pada bulan dan satu bulan sebelum hari raya Idul Fitri mempunyai nilai yang tidak berbeda jauh. Untuk tingkat Nasional, rata-rata *outflow* sebesar 45,23 miliar pada satu bulan sebelum hari raya Idul Fitri dan 37,55 miliar pada saat bulan hari raya Idul Fitri. Sementara untuk tingkat Provinsi NTT, rata-rata *outflow* sebesar 3,86 miliar pada satu bulan sebelum hari raya Idul Fitri dan 2,61 miliar pada saat bulan hari raya Idul Fitri.

Peningkatan rata-rata *outflow* jika hari raya Idul Fitri jatuh pada minggu ketiga merupakan kondisi yang berbanding terbalik dengan hari raya Idul Fitri yang jatuh pada minggu pertama. Dapat ditunjukkan bahwa rata-rata *outflow* akan mengalami peningkatan pada bulan saat terjadi hari raya Idul Fitri di masing-masing tingkatan. Untuk tingkat Nasional, rata-rata *outflow* pada bulan hari raya Idul Fitri sebesar 74,58 miliar dan pada satu bulan sebelum hari raya Idul Fitri hanya sebesar 35,21 miliar. Sementara pada tingkat Provinsi NTT, rata-rata *outflow* pada bulan hari raya Idul Fitri sebesar 4,76 miliar dan pada satu bulan sebelum hari raya Idul Fitri hanya sebesar 2,58 miliar. Apabila hari raya Idul Fitri jatuh pada minggu keempat, maka rata-rata *outflow* akan meningkat pada bulan hari raya Idul Fitri. Peningkatan *outflow* sebesar 79,52 miliar dari 33,37 miliar untuk Nasional dan 5,48 miliar dari 3,75 miliar untuk tingkat Provinsi NTT. Hal tersebut merupakan kondisi yang sama dengan hari raya Idul Fitri yang jatuh pada minggu ketiga. Dari uraian diatas dapat dikatakan bahwa pergerakan *inflow* dan *outflow* uang kartal di BI Provinsi NTT mengikuti pergerakan *inflow* dan *outflow* uang kartal di tingkat Nasional dengan besaran yang relatif kecil dibanding tingkat nasional mengingat faktor-faktor pendukung pergerakan *inflow* dan *outflow* di kedua tempat ini berbeda.

Adapun statistika deskriptif yang dapat menjelaskan mengenai gambaran umum dari data *outflow* dan *inflow* mulai bulan Januari 2005 hingga Desember 2016 dapat dilihat pada Tabel 4.30.

**Tabel 4.30** Karakteristik *Inflow* dan *Outflow* Nasional dan NTT

Variabel	Rata-Rata	St.dev	Maks	Min
<i>Inflow</i> NTT	213,800	146,000	1003	41,000
<i>Outflow</i> NTT	320,300	267,900	1575,000	28,800
<i>Inflow</i> Nasional	28029,900	17208,350	108976,060	7295,140
<i>Outflow</i> Nasional	31194,550	21594,470	137875,750	4241,020

Pada tabel tersebut diketahui bahwa rata-rata *inflow* uang kartal selama periode pengamatan yaitu januari 2005 hingga desember 2016 sebesar 213,8 sedangkan rata-rata *inflow* uang kartal nasional dari Januari 2005 hingga Desember 2016 sebesar 28029,90. Berdasarkan Tabel 4.29 dapat diketahui pula bahwa rata-rata *outflow* uang kartal selama periode pengamatan yaitu Januari 2005 hingga Desember 2016 sebesar 320,3 sedangkan rata-rata *outflow* uang kartal nasional dari januari 2005 hingga desember 2016 sebesar 31194,55. Nilai standar deviasi untuk *inflow* uang kartal di BI NTT pada januari 2005 hingga desember 2016 sebesar 146,0 sedangkan standar deviasi *inflow* uang kartal nasional sebesar 17208,35. Nilai standar deviasi untuk *outflow* pada Januari 2005 hingga desember 2016 sebesar 267,9 sedangkan standar deviasi untuk nasional sebesar 21594,47. Hal tersebut menjelaskan bahwa data uang kartal selama periode pengamatan menyebar cukup jauh dari ukuran pemusatan data (dalam hal ini nilai rata-rata) atau dengan kata lain pergerakan *inflow* dan *outflow* uang kartal selama periode pengamatan memiliki varians yang tinggi.

#### **4.3 Model *Hybrid* ARIMAX-QR untuk *Inflow* dan *Outflow* Uang Kartal Provinsi NTT dan Nasional**

Pada tahap analisis karakteristik *inflow* dan *outflow* uang kartal di NTT didapatkan bahwa *inflow* dan *outflow* mengalami kenaikan pada bulan-bulan tertentu setiap tahunnya. Hal ini menunjukkan bahwa perbedaan bulan akan memberikan efek yang berbeda pada nilai *inflow* dan *outflow* uang kartal di NTT. Selain itu adanya perayaan Idul Fitri tampak memberi pengaruh terhadap *inflow*

dan *outflow* uang kartal di NTT. Dengan demikian, efek bulan dan Idul Fitri akan disertakan pada pemodelan ARIMAX dalam bentuk variabel *dummy*.

#### 4.3.1 Model *Hybrid* ARIMAX-QR untuk *Inflow* Uang Kartal Provinsi NTT

Tahap awal pembentukan model *hybrid* ARIMAX-QR adalah mengacu pada pemodelan regresi *time series*. Model regresi *time series* untuk *inflow* uang kartal dapat diduga sebagai berikut.

$$Y_{1t} = \alpha + r_1 M_1 + r_2 M_2 + r_3 M_3 + r_4 M_4 + r_5 M_5 + r_6 M_6 + r_7 M_7 + r_8 M_8 + r_9 M_9 + r_{10} M_{10} + r_{11} M_{11} + r_{12} M_{12} + s_1 V_{1,t} + s_2 V_{2,t} + s_3 V_{3,t} + s_4 V_{4,t} + x_1 V_{1,t+1} + x_2 V_{2,t+1} + x_3 V_{3,t+1} + x_4 V_{4,t+1} + a_t \quad (4.18)$$

Tahap selanjutnya adalah melakukan estimasi parameter dari model dugaan tersebut. Berdasarkan hasil estimasi parameter maka Persamaan 4.18 dapat dituliskan menjadi

$$Y_{1t} = 1,151t + 371,017M_1 + 194,684M_2 + 133,123M_3 + 98,057M_4 + 79,551M_5 + 65,730M_6 + 102,245M_7 + 130,557M_8 + 77,167M_9 + 74,724M_{10} + 60,345M_{11} + 43,335M_{12} + 89,553V_{1,t} + 38,161V_{2,t} + 33,433V_{3,t} - 6,304V_{4,t} + 81,723V_{1,t+1} - 20,134V_{2,t+1} - 36,121V_{3,t+1} + 122V_{4,t+1} + a_t \quad (4.19)$$


Model ARIMAX *inflow* uang kartal Provinsi NTT mengacu pada model regresi *time series* pada Persamaan 4.19. Persamaan tersebut menghasilkan residual yang belum *white noise* karena semua nilai *P-value* yang kurang dari 5% hingga lag ke 36. Hal ini dapat dilihat pada Tabel 4.31

**Tabel 4.31** Hasil Uji Asumsi *White Noise* ARIMAX *Inflow* NTT

Lag	Chi-square	DF	P_value
6	98,030	6	2,2e-16
12	140,830	12	2,2e-16
24	163,860	24	2,2e-16
36	184,090	36	2,2e-16



Tabel 4.31 menunjukkan bahwa asumsi residual independen tidak terpenuhi karena semua nilai  $p$ -value yang kurang dari 5% , oleh karena itu lag yang signifikan berdasarkan plot ACF dan PACF ditambahkan pada persamaan 4.19 dan kemudian dilakukan estimasi ulang.



**Gambar 4.10** Plot ACF dan PACF dari Residual Regresi *Time series Intflow* Uang Kartal

Berdasarkan plot ACF dan PACF pada Gambar 4.10 dapat dibentuk model ARIMA(1,0,0)(1,0,0)<sup>12</sup>. Model ARIMA yang diperoleh akan dilakukan pengujian signifikansi parameter dan pengecekan asumsi residual independen. Hasil pengujian tersebut dapat dilihat pada Tabel 4.32

**Tabel 4.32** Hasil Pengujian Signifikansi Parameter

Model	Parameter	Estimasi	T_value	$P$ -value
ARIMA (1,0,0)(1,0,0) <sup>12</sup>	$\omega_1$	0,361	4,420	0,000
	$\Phi_{12}$	0,634	7,340	0,000

Berdasarkan Tabel 4.32 dapat dilihat bahwa semua parameter pada model ARIMA(1,0,0)(1,0,0)<sup>12</sup> signifikan dan menghasilkan residual yang independen. Pernyataan tersebut dijelaskan pada Tabel 4.33 dimana tidak ada nilai  $p$ -value yang kurang dari  $\alpha=5\%$  hingga lag ke 36.

**Tabel 4.33** Hasil uji asumsi Independen residual ARIMA

Lag	ARIMA(1,0,0)(1,0,0) <sup>12</sup>		
	t <sup>2</sup>	Df	P-value
6	7,640	4	0,106
12	10,640	10	0,387
24	16,050	22	0,813
36	23,590	34	0,910

Model tersebut akan dianalisis lebih lanjut untuk membentuk model ARIMAX. Hasil analisis model tersebut mengikuti persamaan

$$v_t = 0,361v_{t-1} + 0,634v_{t-12} - 0,229v_{t-13} + a_t \quad (4.20)$$

Model ARIMA dari residual regresi *time series* pada persamaan (4.20) telah memenuhi asumsi independen, tahap berikutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* variasi kalender dan kemudian diestimasi secara simultan. Berdasarkan hasil estimasi parameter yang dilakukan, model ARIMAX dengan efek variasi kalender yang diperoleh adalah sebagai berikut

$$\begin{aligned}
Y_{1t} = & 0,799t + 415,963M_1 + 230,094M_2 + 186,016M_3 + \\
& 128,420M_4 + 122,711M_5 + 119,189M_6 + 165,439M_7 + \\
& 179,612M_8 + 131,128M_9 + 114,063M_{10} + 98,686M_{11} + \\
& 106,736M_{12} + 84,451V_{1,t} + 60,469V_{2,t} + 36,749V_{3,t} - \\
& 13,254V_{4,t} + 35,130V_{1,t+1} - 17,654V_{2,t+1} - 14,112V_{3,t+1} + \\
& 93,657V_{4,t+1} + \frac{1}{(1-0,360B)(1-0,695B^{12})} a_t
\end{aligned} \quad (4.21)$$

Selanjutnya dilakukan uji Kolmogorov-Smirnov (KS) komponen residual pada persamaan (4.21). Hasil pengujian ini menyimpulkan bahwa residual belum berdistribusi normal karena *p-value* kurang dari 0,05 (kurang dari 5% ) dengan nilai  $D=0,098$ . Ketidaknormalan residual biasanya disebabkan karena adanya *outlier*. Pada penelitian ini tidak dilakukan pendeteksian outlier. Model ARIMAX efek variasi kalender dengan residual yang belum berdistribusi normal tetap digunakan untuk pemodelan selanjutnya yakni QR. Hal ini didukung oleh

Koenker (2005) yang menunjukkan bagaimana data untuk outlier dapat diselesaikan dengan menggunakan regresi *quantile*.

Model ARIMAX efek variasi kalender yang diperoleh pada Persamaan 4.21 menghasilkan estimasi parameter dengan beberapa parameter yang tidak signifikan seperti yang terlihat pada Tabel 4.33. Parameter yang tidak signifikan tersebut akan tetap digunakan untuk mendapatkan nilai prediksi model ARIMAX(1,0,0)(1,0,0)<sup>12</sup>. Nilai prediksi tersebut akan digunakan pada tahap selanjutnya dalam peramalan *hybrid* model ARIMAX-QR.

**Tabel 4.34** Hasil Estimasi Parameter Model ARIMAX(1,0,0)(1,0,0)<sup>12</sup>

Parameter	Estimate	Standar Error	t-value	<i>P-value</i>
$w_1$	0,360	0,0903	3,990	0,000
$\Phi_1$	0,695	0,0931	7,470	0,000
$u$	0,799	0,4952	1,610	0,109
$r_1$	415,963	62,729	6,630	0,000
$r_2$	230,094	65,302	3,520	0,000
$r_3$	186,016	65,971	2,820	0,006
$r_4$	128,420	66,323	1,940	0,055
$r_5$	122,711	66,454	1,850	0,068
$r_6$	119,189	66,625	1,790	0,076
$r_7$	165,439	67,203	2,460	0,015
$r_8$	179,611	67,996	2,640	0,009
$r_9$	131,128	67,492	1,940	0,054
$r_{10}$	114,063	67,633	1,690	0,095
$r_{11}$	98,686	72,627	1,360	0,177
$r_{12}$	106,736	67,916	1,570	0,119
$s_1$	84,451	57,555	1,470	0,145
$s_2$	60,469	48,798	1,240	0,218
$s_3$	36,749	48,477	0,760	0,450
$s_4$	-13,255	42,825	-0,310	0,758
$x_1$	35,130	50,709	0,690	0,490
$x_2$	-17,654	44,58	-0,400	0,693
$x_3$	-14,112	52,265	-0,270	0,788
$x_4$	93,657	50,106	1,870	0,064

Hasil akurasi peramalan *inflow* uang kartal BI NTT menggunakan model ARIMAX (1,0,0)(1,0,0)<sup>12</sup> dapat dilihat pada Tabel 4.34

**Tabel. 4.35** Akurasi Peramalan Menggunakan Model ARIMAX(1,0,0)(1,0,0)<sup>12</sup>

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	79,349	59,861
MdAE	37,288	36,122

Berdasarkan akurasi peramalan *inflow* uang kartal menggunakan model ARIMAX pada Tabel 4.34, maka model terbaik yang diperoleh adalah model ARIMAX yang telah memenuhi asumsi residual *white noise*. Model tersebut dilanjutkan pada pengujian varians residual homogen. Pendeteksian terhadap homogenitas varians dilakukan dengan cara pemeriksaan terhadap residual kuadrat dari model ARIMAX dengan efek variasi kalender dengan menggunakan uji *Lagrange Multiplier* (LM). Uji LM digunakan untuk mendeteksi adanya proses ARCH/GARCH, yaitu heterokedastisitas varians residual yang dipengaruhi oleh residual kuadrat periode sebelumnya atau biasa disebut heterokedastisitas varians residual bersyarat (*conditional heterocedasticity*) dalam deret waktu. Hipotesis awal varians residual homogen (tidak terdapat proses ARCH/GARCH). Hasil uji LM disajikan pada Tabel 4.36.

**Tabel 4.36** Uji Heteroskedastisitas Model ARIMAX Data *Inflow*

$K$	$t^2$	$P\text{-value}$
1	0,281	0,596
2	0,851	0,653
3	1,571	0,666
⋮	⋮	⋮
12	6,865	0,866

Hasil uji heterokedastisitas model ARIMAX menggunakan Uji LM pada Tabel 4.36 menunjukkan varians residual homogen karena semua nilai *p-value* lebih besar dari 0,05 ( = 5%). Sehingga model ARIMAX dengan variasi kalender *inflow* uang kartal BI NTT pada persamaan 4.21 tidak memiliki efek ARCH/GARCH atau bersifat homokedastisitas

Tahap selanjutnya adalah melakukan peramalan dengan menggunakan *hybrid* ARIMAX-QR. Pemodelan menggunakan metode *hybrid* ARIMAX-QR dilakukan dengan pemodelan regresi kuantil antara data *inflow* dan prediksi data *inflow* pada model ARIMAX yang telah di peroleh sebelumnya sebagai variabel prediktor. Hasil estimasi parameter yang diperoleh dari model *hybrid* ARIMAX-QR dengan efek variasi kalender dapat dilihat pada Tabel 4.37

**Tabel 4.37** Hasil Estimasi Parameter Model *Hybrid* ARIMAX-QR *Inflow* Uang Kartal BI Provinsi NTT

Kuantil	Estimasi	Standar Error	T value	<i>P-value</i>
2,5%	0,379	0,032	11,902	0,000
50%	0,957	0,025	38,188	0,000
97,5%	1,639	0,037	44,555	0,000

Berdasarkan Tabel 4.37 estimasi parameter dengan menggunakan metode ARIMAX-QR menghasilkan nilai estimasi parameter yang berbeda-beda sesuai dengan nilai kuantil dari Y dimana semakin besar kuantil semakin besar pula nilai estimasinya. Hasil uji signifikansi menunjukan bahwa nilai estimasi parameter pada setiap kuantil telah signifikan sehingga nilai Y diduga berdasarkan nilai kuantilnya. Persamaan regresi untuk kuantil 2,5%, 50%, dan 97,5% dapat dilihat pada Persamaan 4.22:

$$\begin{aligned}
 Y_{1t}(2,5\%) &= 0,379\hat{Z}_{1t} + a_t \\
 Y_{1t}(50\%) &= 0,957\hat{Z}_{1t} + a_t \\
 Y_{1t}(97,5\%) &= 1,639\hat{Z}_{1t} + a_t
 \end{aligned}
 \tag{4.22}$$

Dengan  $\hat{Z}_{1t}$  merupakan nilai prediksi model ARIMAX. Dari model *hybrid* ARIMAX-QR pada setiap kuantil ini selanjutnya akan diperoleh peramalan pada setiap kuantil yang akan di sajikan pada Tabel 4.38

**Tabel 4.38** Peramalan Menggunakan Model ARIMAX-QR untuk *Inflow* Uang Kartal BI Provinsi NTT


Bulan	Kuantil		
	2,5%	50%	97,5%
Januari	323,796	817,501	1400,617
Februari	162,078	409,204	701,0863
Maret	125,047	315,712	540,9063
April	73,396	185,305	317,481
Mei	72,650	183,422	314,2561
Juni	71,656	180,912	309,9548
Juli	161,270	407,165	697,5923
Agustus	113,668	286,982	491,6843
September	87,274	220,343	377,5115
Oktober	71,204	179,772	308,0015
November	76,021	191,933	328,8368
Desember	75,303	190,121	325,7328

Hasil akurasi peramalan *inflow* uang kartal BI Provinsi NTT menggunakan model ARIMAX-QR pada setiap kuantil dapat dilihat pada Tabel 4.39

**Tabel 4.39** Akurasi Peramalan Menggunakan Model ARIMAX-QR

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	73,552	71,437
MdAE	41,003	54,146

Berdasarkan Tabel 4.39 model ARIMAX-QR menghasilkan nilai ramalan yang baik menggunakan kriteria RMSE. Secara visual peramalan *inflow* uang kartal BI Provinsi NTT dapat dilihat pada Gambar 4.11 berikut



**Gambar 4.11** Ramalan *Out-sample* Model Hybrid ARIMAX-QR *Inflow* Uang Kartal BI NTT

Berdasarkan Gambar 4.11 dapat disimpulkan bahwa permalan dengan menggunakan ARIMAX-QR menghasilkan nilai ramalan yang mengikuti pola data aktual.

#### 4.3.2 Model Hybrid ARIMAX-QR untuk *Outflow* Uang Kartal Provinsi NTT

Tahap awal pembentukan model *hybrid* ARIMAX-QR adalah mengacu pada pemodelan regresi *time series*. Model regresi *time series* untuk *outflow* uang kartal dapat diduga sebagai berikut:

$$\begin{aligned}
Y_{2t} = & \sim_t + r_1 M_1 + r_2 M_2 + r_3 M_3 + r_4 M_4 + r_5 M_5 + r_6 M_6 + \\
& r_7 M_7 + r_8 M_8 + r_9 M_9 + r_{10} M_{10} + r_{11} M_{11} + r_{12} M_{12} + \\
& s_1 V_{1,t} + s_2 V_{2,t} + s_3 V_{3,t} + s_4 V_{4,t} + y_1 V_{1,t+1} + y_2 V_{2,t+1} + y_3 V_{3,t+1} + y_4 V_{4,t+1} + a_t
\end{aligned} \tag{4.23}$$

Tahap selanjutnya adalah melakukan estimasi parameter dari model dugaan tersebut. Berdasarkan hasil estimasi parameter maka Persamaan 4.6 dapat dituliskan menjadi

$$\begin{aligned}
Y_{2t} = & 1,647t + 28,976M_1 - 16,223M_2 + 53,235M_3 + 83,463M_4 + \\
& 134,222M_5 + 253,288M_6 + 284,895M_7 + 91,354M_8 + \\
& 137,054M_9 + 135,062M_{10} + 220,149M_{11} + 785,744M_{12} - \\
& 24,052V_{1,t} + 26,578V_{2,t} + 153,284V_{3,t} + 257,155V_{4,t} + \\
& 223,543V_{1,t+1} + 88,362V_{2,t+1} - 44,563V_{3,t+1} + 32,173V_{4,t+1} + a_t
\end{aligned} \tag{4.23}$$


Model ARIMAX *outflow* uang kartal mengacu pada model regresi *time series* pada Persamaan 4.23. Persamaan tersebut menghasilkan residual yang belum *white noise* karena semua nilai *p-value* yang kurang dari 5% hingga lag ke 36. Hal ini dapat dilihat pada Tabel 4.40

**Tabel 4.40** Hasil Uji Asumsi Independen Residual Regresi *Time series Outflow* NTT

Lag	Chi-square	DF	P_value
6	27,410	6	0,000
12	69,010	12	0,000
24	94,300	24	0,000
36	106,690	36	0,000

Tabel 4.40 menunjukkan bahwa asumsi residual independen tidak terpenuhi karena semua nilai *p-value* yang kurang dari 5% maka lag yang signifikan berdasarkan plot ACF dan PACF ditambahkan dalam Persamaan 4.23 dan kemudian dilakukan estimasi ulang.





**Gambar 4.12** Plot ACF dan PACF dari Residual Regresi *Time Series Outflow* Uang Kartal NTT

Berdasarkan plot ACF dan PACF pada Gambar 4.12 dapat dibentuk model  $ARIMA([1,2],0,0)(1,0,0)^{12}$ . Model  $ARIMA$  yang diperoleh akan dilakukan pengujian signifikansi parameter dan pengecekan asumsi residual independen. Hasil uji signifikansi menunjukkan bahwa ada parameter yang tidak signifikan. Parameter ini tetap dimasukkan kedalam persamaan mengingat tujuan akhir adalah memperoleh nilai ramalan terbaik. Hal ini didukung oleh penelitian Andrev dan Hyndman (2008) tentang uji signifikan dalam bidang peramalan. Hasil pengujian tersebut dapat dilihat pada Tabel 4.41

**Tabel 4.41** Hasil Pengujian Signifikansi Parameter

Model	Parameter	Estimasi	t_value	P-value
$ARIMA([1,2],0,0)(1,0,0)^{12}$	$w_1$	0,086	1,09	0,278
	$w_2$	0,213	2,66	0,000
	$\Phi_1$	0,562	6,76	0,000

Parameter pada model  $ARIMA([2],0,0)(1,0,0)^{12}$  menghasilkan residual yang independen. Pernyataan tersebut dijelaskan pada Tabel 4.42 dimana tidak ada nilai *p-value* yang kurang dari  $\alpha=5\%$  hingga lag ke 36.

**Tabel 4.42** Hasil Uji Asumsi Independen Residual ARIMA([1,2],0,0)(1,0,0)<sup>12</sup>

Lag	ARIMA([1,2],0,0)(1,0,0) <sup>12</sup>		
	$t^2$	Df	<i>P-value</i>
6	3,970	3	0,265
12	5,990	9	0,741
24	17,890	21	0,656
36	31,690	33	0,532

Model tersebut akan dianalisis lebih lanjut untuk membentuk model ARIMAX.

Hasil analisis model tersebut mengikuti persamaan

$$v_t = 0,086v_{t-1} - 0,213v_{t-2} - 0,562v_{t-12} + 0,048v_{t-13} + 0,119v_{t-14} + a_t \quad (4.24)$$

Model ARIMA dari residual regresi *time series* pada Persamaan (4.8) telah memenuhi asumsi independen, tahap berikutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* variasi kalender dan kemudian diestimasi secara simultan. Berdasarkan hasil estimasi parameter yang dilakukan, diperoleh model ARIMAX dengan efek variasi kalender pada Persamaan 4.24

$$\begin{aligned}
Y_{2t} = & 1,789t + 157,453M_1 + 17,828M_2 + 170,235M_3 + \\
& 112,787M_4 + 210,685M_5 + 253,816M_6 + 374,731M_7 + \\
& 64,299M_8 + 268,434M_9 + 1,370M_{10} + 368,063M_{11} + \\
& 699,285M_{12} - 42,004V_{1,t} + 122,912V_{2,t} + 168,981V_{3,t} + \\
& 237,347V_{4,t} + 364,877V_{1,t+1} + 73,022V_{2,t+1} - 46,7129V_{3,t+1} + \\
& 12,336V_{4,t+1} + \frac{1}{(1-0,009B-0,277B^2)(1-0,714B^{12})} a_t
\end{aligned} \quad (4.25)$$

Selanjutnya dilakukan uji Kolmogorov-Smirnov (KS) komponen residual pada persamaan (4.25). Hasil pengujian ini menyimpulkan bahwa residual telah berdistribusi normal karena *p-value* lebih dari 0,05 (kurang dari 5% ) dengan nilai  $D=0,07334$ . Model ARIMAX efek variasi kalender yang diperoleh pada Persamaan 4.25 menghasilkan estimasi parameter dengan beberapa parameter yang tidak signifikan seperti yang terlihat pada Lampiran. Parameter yang tidak

signifikan tersebut akan tetap digunakan untuk mendapatkan nilai prediksi model ARIMAX([1,2],0,0)(1,0,0)<sup>12</sup>. Nilai prediksi tersebut akan digunakan pada tahap selanjutnya dalam peramalan *hybrid* model ARIMAX-QR.

Hasil akurasi peramalan *outflow* uang kartal BI NTT menggunakan model ARIMAX ([1,2],0,0)(1,0,0)<sup>12</sup> dapat dilihat pada Tabel 4.43

**Tabel 4.43** Akurasi Peramalan Menggunakan Model ARIMAX ([1,2],0,0)(1,0,0)<sup>12</sup>

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	106,095	112,309
MdAE	50,372	96,006

Berdasarkan akurasi peramalan *inflow* uang kartal menggunakan model ARIMAX pada Tabel 4.43, maka model terbaik yang diperoleh adalah model ARIMAX ([1,2],0,0)(1,0,0)<sup>12</sup> yang telah memenuhi asumsi residual *white noise*, berdistribusi normal. Model tersebut dilanjutkan pada pengujian varians residual homogen. Pendeteksian terhadap homogenitas varians dilakukan dengan cara pemeriksaan terhadap residual kuadrat dari model ARIMAX dengan efek variasi kalender dengan menggunakan uji *Lagrange Multiplier* (LM). Uji LM digunakan untuk mendeteksi adanya proses ARCH/GARCH, yaitu heterokedastisitas varians residual yang dipengaruhi oleh residual kuadrat periode sebelumnya atau biasa disebut heterokedastisitas varians residual bersyarat (*conditional heterocedasticity*) dalam deret waktu. Hipotesis awal varians residual homogen (tidak terdapat proses ARCH/GARCH). Hasil uji LM disajikan pada Tabel 4.44.

**Tabel 4.44** Uji Heteroskedastisitas Model ARIMAX Data *Outflow* Uang Kartal BI NTT

$K$	$t^2$	$P\text{-value}$
1	0,696	0,404
2	1,529	0,465
3	1,578	0,664
$\vdots$	$\vdots$	$\vdots$
12	9,670	0,644

Hasil uji heteroskedastisitas model menggunakan Uji LM pada Tabel 4.44 menunjukkan varians residual homogen karena  $p\text{-value}$  yang lebih kecil dari 0,05 ( $\alpha = 5\%$ ). Sehingga model ARIMAX dengan variasi kalender *outflow* uang kartal BI Provinsi NTT pada Persamaan 4.9 bersifat homogen

Tahap selanjutnya adalah melakukan peramalan dengan ARIMAX-QR menggunakan hasil prediksi pada metode ARIMAX. Hasil estimasi parameter yang dilakukan dengan model *hybrid* ARIMAX-QR dengan efek variasi kalender yang diperoleh adalah sebagai berikut

**Tabel 4.45** Hasil Estimasi Parameter Model *hybrid* ARIMAX-QR *Outflow* Uang Kartal BI Provinsi NTT

Kuantil	Estimasi	Standar Error	T value	$P\text{-value}$
2,5%	0,323	0,005	69,219	0,000
50%	0,995	0,027	36,704	0,000
97,5%	1,665	0,026	63,188	0,000

Berdasarkan Tabel 4.45 estimasi parameter dengan menggunakan metode ARIMAX-QR untuk *outflow* uang kartal BI provinsi NTT, menghasilkan nilai estimasi parameter yang berbeda-beda sesuai dengan nilai kuantil dari  $Y$  dimana semakin besar kuantil semakin besar pula nilai estimasinya. Hasil uji signifikansi menunjukan bahwa nilai estimasi parameter pada setiap kuantil telah signifikan

sehingga nilai  $Y$  diduga berdasarkan nilai kuantilnya. Persamaan regresi untuk kuantil 2,5%, 50% dan 97,5% dapat dilihat pada Persamaan 4.26:

$$\begin{aligned} Y_{2t}(2,5\%) &= 0,323\hat{Z}_{2t} + a_t \\ Y_{2t}(50\%) &= 0,995\hat{Z}_{2t} + a_t \\ Y_{2t}(97,5\%) &= 1,665\hat{Z}_{2t} + a_t \end{aligned} \quad (4.26)$$

Dengan  $\hat{Z}_{2t}$  merupakan nilai prediksi model ARIMAX. Dari model *hybrid* ARIMAX-QR pada setiap kuantil ini selanjutnya akan diperoleh peramalan pada setiap kuantil yang akan di sajikan pada Tabel 4.46

**Tabel 4.46** Peramalan Menggunakan Model ARIMAX-QR untuk *Outflow* Uang Kartal Provinsi NTT


Bulan	Kuantil		
	2,5%	50%	97,5%
Januari	54,392	167,454	280,328
Februari	103,710	319,285	534,502
Maret	66,082	203,446	340,580
April	118,460	364,686	610,506
Mei	77,662	239,095	400,259
Juni	271,730	836,584	1400,490
Juli	188,780	581,178	972,926
Agustus	120,240	370,187	619,715
September	156,110	480,622	804,589
Oktober	146,470	450,933	754,888
November	180,390	555,359	929,703
Desember	474,880	1461,99	2447,460

Hasil akurasi peramalan *outflow* uang kartal BI NTT menggunakan model ARIMAX-QR pada setiap kuantil dapat dilihat pada Tabel 4.47

**Tabel 4.47** Akurasi Peramalan Menggunakan Model ARIMAX-QR untuk *Outflow* Uang Kartal BI Provinsi NTT

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	97,779	111,594
MdAE	51,328	91,563

Berdasarkan Tabel 4.47 model ARIMAX-QR menghasilkan nilai ramalan yang baik menggunakan kriteria RMSE. Secara visual peramalan *outflow* uang kartal BI Provinsi NTT dapat dilihat pada Gambar 4.13 berikut



**Gambar 4.13** Ramalan *Out-sample* ARIMAX-QR *Outflow* Uang Kartal Provinsi NTT

Berdasarkan Gambar 4.24 dapat disimpulkan bahwa permalan dengan menggunakan ARIMAX-QR untuk *outflow* uang kartal BI provinsi NTT menghasilkan nilai ramalan yang mengikuti pola data aktual. Model ARIMAX-QR dengan rentang kuantil yang ada telah mampu menangkap pola variasi kalender akibat hari raya Idul Fitri pada bulan Juli 2016.

#### 4.3.3 Model *Hybrid* ARIMAX-QR untuk *Inflow* Uang Kartal Nasional

Tahap awal pembentukan model *hybrid* ARIMAX-QR untuk *inflow* uang kartal Nasional adalah mengacu pada pemodelan regresi *time series*. Model regresi *time series* untuk *inflow* uang kartal Nasional dapat diduga sebagai berikut.

$$Y_{3t} = \alpha + r_1 M_1 + r_2 M_2 + r_3 M_3 + r_4 M_4 + r_5 M_5 + r_6 M_6 + r_7 M_7 + r_8 M_8 + r_9 M_9 + r_{10} M_{10} + r_{11} M_{11} + r_{12} M_{12} + s_1 V_{1,t} + s_2 V_{2,t} + s_3 V_{3,t} + s_4 V_{4,t} + x_1 V_{1,t+1} + x_2 V_{2,t+1} + x_3 V_{3,t+1} + x_4 V_{4,t+1} + a_t \quad (4.27)$$

Tahap selanjutnya adalah melakukan estimasi parameter dari model dugaan tersebut. Berdasarkan hasil estimasi parameter maka Persamaan 4.28 dapat dituliskan menjadi


$$Y_{3t} = 194,032t + 26831,001M_1 + 11899,2M_2 + 9760,095M_3 + 8972,9M_4 + 8195,4M_5 + 7558,4M_6 + 11849,8M_7 + 15231,4M_8 + 7597,6M_9 + 11277,9M_{10} + 5055,9M_{11} + 2010,3M_{12} + 29606,7V_{1,t} + 25730,9V_{2,t} + 17530,8V_{3,t} - 6624,1V_{4,t} + 10585,2V_{1,t+1} + 934,261V_{2,t+1} + 11724,1V_{3,t+1} + 438844,5V_{4,t+1} + a_t \quad (4.28)$$

Model ARIMAX untuk *inflow* uang kartal Nasional mengacu pada model regresi *time series* pada Persamaan 4.28. Persamaan tersebut menghasilkan residual yang belum *white noise* karena semua nilai *p-value* yang kurang dari 5% hingga lag ke 36. Hal ini dapat dilihat pada Tabel 4.48

**Tabel 4.48** Hasil uji asumsi Independen residual Regresi *Time series Inflow* Nasional

Lag	Chi-square	DF	<i>P-value</i>
6	202,930	6	0,000
12	332,110	12	0,000
24	380,510	24	0,000
36	392,980	36	0,000

Tabel 4.48 menunjukkan bahwa asumsi residual independen tidak terpenuhi karena semua nilai *p-value* yang kurang dari 5% , oleh karena itu lag yang signifikan berdasarkan plot ACF dan PACF ditambahkan pada Persamaan 4.28 dan kemudian dilakukan estimasi ulang.



**Gambar 4.14** Plot ACF dan PACF dari Residual Regresi *Time Series Inflow* Uang Kartal Nasional

Berdasarkan plot ACF dan PACF pada Gambar 4.14 dapat dibentuk model ARIMA([2,3,5],0,0). Model ARIMA yang diperoleh akan dilakukan pengujian signifikansi parameter dan pengecekan asumsi residual independen. Hasil pengujian tersebut dapat dilihat pada Tabel 4.49

**Tabel 4.49** Hasil Pengujian Signifikansi Parameter *Inflow* Uang Kartal BI Nasional

Model	Parameter	Estimasi	<i>T-value</i>	<i>P-value</i>
ARIMA ([2,3,5],0,0)	$w_2$	0,436	5,35	0,000
	$w_3$	0,421	5,20	0,000
	$w_5$	0,222	2,58	0,001

Berdasarkan Tabel 4.49 dapat dilihat bahwa semua parameter pada model ARIMA([2,3,5],0,0) signifikan dan menghasilkan residual yang independen. Pernyataan tersebut dijelaskan pada Tabel 4.50 dimana tidak ada *p-value* yang kurang dari  $\alpha = 5\%$  sehingga lag ke 36.

**Tabel 4.50** Hasil uji asumsi Independen residual ARIMA([2,3,5],0,0)

Lag	ARIMA([2,3,5],0,0)		
	$t^2$	Df	<i>P-value</i>
6	3,550	3	0,312
12	8,570	9	0,478
24	16,650	21	0,732
36	28,000	33	0,714



Model tersebut akan dianalisis lebih lanjut untuk membentuk model ARIMAX. Hasil analisis model tersebut mengikuti persamaan

$$v_t = 0,323v_{t-2} + 0,241v_{t-3} - 0,222v_{t-5} + a_t \quad (4.29)$$

Model ARIMA dari residual regresi *time series* pada Persamaan 4.29 telah memenuhi asumsi independen, tahap berikutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* variasi kalender dan kemudian diestimasi secara simultan. Berdasarkan hasil estimasi parameter yang dilakukan, model ARIMAX dengan efek variasi kalender yang diperoleh adalah sebagai berikut

$$\begin{aligned} Y_{3t} = & 126,672t + 33140,8M_1 + 18563,4M_2 + 16184,8M_3 + \\ & 15615M_4 + 14828,2M_5 + 14097,9M_6 + 18763,4M_7 + \\ & 21522,5M_8 + 13774M_9 + 17684,8M_{10} + 12334,9M_{11} + \\ & 9916,3M_{12} + 26849,9V_{1,t} + 28673,7V_{2,t} + 19006,6V_{3,t} - \\ & 8317,7V_{4,t} + 5646,8V_{1,t+1} + 5904,8V_{2,t+1} + 13675,4V_{3,t+1} + \\ & 41410,7V_{4,t+1} + \frac{1}{(1-0,332B^2-0,281B^3-0,237B^5)}a_t \end{aligned} \quad (4.30)$$

Selanjutnya dilakukan uji Kolmogorov-Smirnov (KS) komponen residual pada Persamaan 4.30. Hasil pengujian ini menyimpulkan bahwa residual belum berdistribusi normal karena *p-value* kurang dari 0,05 (kurang dari 5% ) dengan nilai  $D=0,098$ . Ketidaknormalan residual biasanya disebabkan karena adanya *outlier* sehingga perlu dideteksi *outlier*. Pada penelitian ini tidak dilakukan pendeteksian outlier. Model ARIMAX efek variasi kalender dengan residual yang belum berdistribusi normal tetap digunakan untuk pemodelan selanjutnya yakni QR. Hal ini didukung oleh Koenker (2005) yang menunjukkan bagaimana data untuk *outlier* dapat diselesaikan dengan menggunakan regresi *quantile*.

Model ARIMAX efek variasi kalender untuk *inflow* uang kartal Nasional yang diperoleh pada Persamaan 4.30 menghasilkan estimasi parameter dengan beberapa parameter yang tidak signifikan seperti yang terlihat pada Tabel 4.51. Parameter yang tidak signifikan tersebut akan tetap digunakan untuk mendapatkan nilai prediksi model ARIMAX([2,3,5],0,0). Nilai prediksi tersebut akan digunakan pada tahap selanjutnya dalam peramalan *hybrid* model ARIMAX-QR.

**Tabel 4.51** Hasil Estimasi Parameter Model ARIMAX([2,3,5],0,0)

Parameter	Estimate	Std.Error	<i>T-value</i>	<i>P-value</i>
$w_2$	0,332	0,088	3,780	0,000
$w_3$	0,281	0,089	3,150	0,002
$w_3$	0,237	0,095	2,500	0,014
u	127,200	62,685	2,030	0,045
$r_1$	33141	4625,600	7,160	0,0001
$r_2$	18563	4640,300	4,000	0,000
$r_3$	16185	4682,100	3,460	0,001
$r_4$	15615	4724	3,310	0,001
$r_5$	14828	4737	3,130	0,002
$r_6$	14098	4781,800	2,950	0,004
$r_7$	18763	4832,200	3,880	0,000
$r_8$	21523	4859,600	4,430	0,000
$r_9$	13774	4884,800	2,820	0,006
$r_{10}$	17685	4894,500	3,610	0,001
$r_{11}$	12335	4877,200	2,530	0,013
$r_{12}$	9916	4852,200	2,040	0,043
$s_1$	26850	4911,200	5,470	0,000
$s_2$	28674	4008,400	7,150	0,000
$s_3$	19007	3980,900	4,770	0,000
$s_4$	-8318	3968,500	-2,100	0,038
$x_1$	5647	4893	1,150	0,251
$x_2$	5905	4010,300	1,470	0,144
$x_3$	13675	4020,100	3,400	0,001
$x_4$	41411	3962,100	10,450	0,000

Hasil akurasi peramalan *inflow* uang kartal BI Nasional menggunakan model ARIMAX ([2,3,5],0,0) dapat dilihat pada Tabel 4.50

**Tabel. 4.52** Akurasi Peramalan Menggunakan Model ARIMAX([2,3,5],0,0)  
*Inflow* Uang Kartal BI Nasional

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	7203,483	15486,400
MdAE	3179,188	6489,097

Berdasarkan akurasi peramalan *inflow* uang kartal menggunakan model ARIMAX pada Tabel 4.52, maka model terbaik yang diperoleh adalah model ARIMAX ([2,3,5],0,0) yang telah memenuhi asumsi residual *white noise*. Model tersebut dilanjutkan pada pengujian varians residual homogen. Pendeteksian terhadap homogenitas varians dilakukan dengan cara pemeriksaan terhadap residual kuadrat dari model ARIMAX dengan efek variasi kalender dengan menggunakan uji *Lagrange Multiplier* (LM). Hipotesis awal varians residual homogen (tidak terdapat proses ARCH/GARCH). Hasil uji LM disajikan pada Tabel 4.53.

**Tabel 4.53** Uji Heteroskedastisitas Model ARIMAX Data *Inflow* Uang Kartal BI Nasional

K	$t^2$	<i>P-value</i>
1	1,858	0,172
2	2,080	0,353
3	2,688	2,687
⋮	⋮	⋮
12	12,027	0,443

Hasil uji heterokedastisitas model menggunakan Uji LM pada Tabel 4.53 menunjukkan varians residual homogen karena *p-value* yang lebih dari 0,05 ( = 5%)

pada setiap lag. Sehingga model ARIMAX dengan variasi kalender *inflow* uang kartal pada Persamaan 4.30 bersifat homogen.

Tahap selanjutnya adalah melakukan peramalan dengan menggunakan model *hybrid* ARIMAX-QR. Hasil estimasi parameter yang diperoleh dapat dilihat pada Tabel 4.54

**Tabel 4.54** Hasil Estimasi Parameter Model *hybrid* ARIMAX-QR *Inflow* Uang Kartal BI Nasional

Kuantil	Estimasi	Standar Error	<i>T-value</i>	<i>P-value</i>
2,5%	0,534	0,046	11,632	0,000
50%	0,966	0,019	49,659	0,000
97,5%	1,469	0,033	44,330	0,000

Berdasarkan Tabel 4.54 estimasi parameter dengan menggunakan metode ARIMAX-QR untuk *inflow* uang kartal BI Nasional, menghasilkan nilai estimasi parameter yang berbeda-beda sesuai dengan nilai kuantil dari Y dimana semakin besar kuantil semakin besar pula nilai estimasinya. Hasil uji signifikansi menunjukkan bahwa nilai estimasi parameter pada setiap kuantil telah signifikan sehingga nilai Y diduga berdasarkan nilai kuantilnya. Persamaan regresi untuk kuantil 2,5%, 50%, dan 97,5% dapat dilihat pada Persamaan 4.31:

$$\begin{aligned}
 Y_{3t}(2,5\%) &= 0,534 \hat{Z}_{3t} + a_t \\
 Y_{3t}(50\%) &= 0,966 \hat{Z}_{3t} + a_t \\
 Y_{3t}(97,5\%) &= 1,469 \hat{Z}_{3t} + a_t
 \end{aligned}
 \tag{4.31}$$

Dengan  $\hat{Z}_{3t}$  merupakan nilai prediksi model ARIMAX. Dari model *hybrid* ARIMAX-QR pada setiap kuantil ini selanjutnya akan diperoleh peramalan pada setiap kuantil yang akan disajikan pada Tabel 4.52

**Tabel 4.55** Peramalan Menggunakan Model ARIMAX-QR untuk *Inflow* Uang Kartal Nasional


Bulan	Kuantil		
	2,5%	50%	97,5%
Januari	28441,540	51433,970	78270,010
Februari	20487,400	37049,620	56380,530
Maret	18696,870	33811,600	51453,050
April	19367,750	35024,830	53299,290
Mei	17831,660	32246,960	49072,040
Juni	18150,830	32824,140	49950,370
Juli	34850,650	63024,260	95907,630
Agustus	24811,560	44869,470	68280,440
September	18057,880	32656,050	49694,580
Oktober	19792,010	35792,070	54466,840
November	17192,630	31091,320	47313,440
Desember	15875,610	28709,610	43689,060

Hasil akurasi peramalan *inflow* uang kartal BI Nasional menggunakan model ARIMAX-QR pada setiap kuantil dapat dilihat pada Tabel 4.56

**Tabel 4.56** Akurasi Peramalan Menggunakan Model ARIMAX-QR untuk *Inflow* Uang Kartal BI Nasional

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	6676,233	16539,97
MdAE	3102,838	7575,921

Berdasarkan Tabel 4.56 model ARIMAX-QR menghasilkan nilai ramalan yang baik menggunakan kriteria RMSE. Secara visual peramalan *inflow* uang kartal BI Nasional dapat dilihat pada Gambar 4.26 berikut



**Gambar 4.15** Ramalan Interval *Out-sample Inflow* Uang Kartal ARIMAX-QR BI Nasional

Berdasarkan Gambar 4.15 dapat disimpulkan bahwa permalan interval dengan menggunakan ARIMAX-QR menghasilkan ramalan lebih baik dibandingkan dengan peramalan interval dengan menggunakan konfiden interval. Pada bulan Juli berada diluar peramalan interval. Hal tersebut terjadi karena efek hari raya Idul Fitri yang menyebabkan residual pada bulan tersebut cukup tinggi sehingga tidak mampu ditangkap oleh model ARIMAX-QR.

#### 4.3.4 Model *Hybrid* ARIMAX-QR untuk *Outflow* Uang Kartal Nasional

Tahap awal pembentukan model *hybrid* ARIMAX-QR untuk *outflow* Uang Kartal Nasional adalah mengacu pada pemodelan regresi *time series*. Model regresi *time series* untuk *outflow* Uang Kartal Nasional dapat diduga sebagai berikut.

$$\begin{aligned}
 Y_{4t} = & \alpha + \beta_1 M_1 + \beta_2 M_2 + \beta_3 M_3 + \beta_4 M_4 + \beta_5 M_5 + \beta_6 M_6 \\
 & + \beta_7 M_7 + \beta_8 M_8 + \beta_9 M_9 + \beta_{10} M_{10} + \beta_{11} M_{11} + \beta_{12} M_{12} \\
 & + \gamma_1 V_{1,t} + \gamma_2 V_{2,t} + \gamma_3 V_{3,t} + \gamma_4 V_{4,t} + \delta_1 V_{1,t+1} + \delta_2 V_{2,t+1} + \delta_3 V_{3,t+1} + \delta_4 V_{4,t+1} + a_t
 \end{aligned}
 \quad (4.32)$$

Tahap selanjutnya adalah melakukan estimasi parameter dari model dugaan tersebut. Berdasarkan hasil estimasi parameter maka Persamaan 4.32 dapat dituliskan menjadi


$$\begin{aligned}
Y_{4t} = & 203,16479t + 67,17643M_1 + 3887,7M_2 + 10281,3M_3 + \\
& 12405,7M_4 + 13213,9M_5 + 17141,0M_6 + 20406,5M_7 + \\
& 6242,7M_8 + 5202,2M_9 + 5468,6M_{10} + 11005,4M_{11} + \\
& 38084,7M_{12} - 3886,0V_{1,t} + 17890,2V_{2,t} + 45271,5V_{3,t} + 54114,1V_{4,t} + \\
& 42417,4V_{1,t+1} + 22618,8V_{2,t+1} + 3717,1V_{3,t+1} + 4623,5V_{4,t+1} + a_t
\end{aligned} \tag{4.33}$$

Model ARIMAX *outflow* uang kartal Nasional mengacu pada model regresi *time series* pada Persamaan 4.33. Persamaan tersebut menghasilkan residual yang belum *white noise* karena semua nilai *p-value* yang kurang dari 5% hingga lag ke 36. Hal ini dapat dilihat pada Tabel 4.57

**Tabel 4.57** Hasil Uji Asumsi Independen Residual Regresi *Time series Outflow* Uang Kartal BI Nasional

Lag	Chi-square	DF	<i>P-value</i>
6	155,390	6	0,000
12	268,620	12	0,000
24	313,930	24	0,000
36	323,050	36	0,000

Tabel 4.57 menunjukkan bahwa asumsi residual independen tidak terpenuhi karena semua nilai *p-value* yang kurang dari 5% maka lag yang signifikan berdasarkan plot ACF dan PACF ditambahkan dalam persamaan 4.33 dan kemudian dilakukan estimasi ulang.



**Gambar 4.16** Plot ACF dan PACF dari Residual Regresi *Time Series outflow* Uang Kartal BI Nasional

Berdasarkan plot ACF dan PACF pada Gambar 4.16 dapat dibentuk model ARIMA([2,5],0)(1,0,0)<sup>12</sup>. Model ARIMA yang diperoleh akan dilakukan pengujian signifikansi parameter dan pengecekan asumsi residual independen. Hasil pengujian tersebut dapat dilihat pada Tabel 4.58

**Tabel 4.58** Hasil Pengujian Signifikansi Parameter

Model	Parameter	Estimasi	<i>T-value</i>	<i>P-value</i>
ARIMA ([2,5],0,0)(1,0,0) <sup>12</sup>	$w_2$	0,398	4,93	0,000
	$w_5$	0,264	3,12	0,002
	$\Phi_1$	0,400	4,32	0,000

Model tersebut akan dianalisis lebih lanjut untuk membentuk model ARIMAX. Hasil analisis model tersebut mengikuti persamaan

$$v_t = 0,398v_{t-2} - 0,264v_{t-5} - 0,400v_{t-12} + 0,159v_{t-14} + 0,106v_{t-17} + a_t \quad (4.34)$$

Model ARIMA dari residual regresi *time series* pada Persamaan 4.34 telah memenuhi asumsi independen, tahap berikutnya adalah membentuk model ARIMAX yakni gabungan antara model ARIMA dan model regresi *time series* variasi kalender dan kemudian diestimasi secara simultan. Berdasarkan hasil estimasi parameter yang dilakukan, model ARIMAX dengan efek variasi kalender yang diperoleh adalah sebagai berikut

$$\begin{aligned}
Y_{4t} = & 196,315t + 18479,1M_1 + 18763,7M_2 + 22838,8M_3 + \\
& 22751,8M_4 + 22967,0M_5 + 25836,6M_6 + 28181,4M_7 + \\
& 23960,7M_8 + 28850,6M_9 - 5287,3M_{10} + 19704,1M_{11} + \\
& 33141,8M_{12} - 6643,1V_{1,t} + 28936,6V_{2,t} + 39729,5V_{3,t} + \\
& 48143,4V_{4,t} + 52482,7V_{1,t+1} + 18459,7V_{2,t+1} - 1528,2V_{3,t+1} + \\
& 1107,1V_{4,t+1} + \frac{1}{(1-0,540B^2-0,171B^5)(1-0,981B^{12})}a_t
\end{aligned} \quad (4.35)$$

Selanjutnya dilakukan uji Kolmogorov-Smirnov (KS) komponen residual pada Persamaan 4.35. Hasil pengujian ini menyimpulkan bahwa residual belum berdistribusi normal karena *p-value* kurang dari 0,05 (kurang dari 5% ) dengan nilai  $D=0,098$ . Ketidaknormalan residual biasanya disebabkan karena adanya



*outlier* sehingga perlu dideteksi *outlier*. Pada penelitian ini tidak dilakukan pendeteksian *outlier*. Model ARIMAX efek variasi kalender dengan residual yang belum berdistribusi normal tetap digunakan untuk pemodelan selanjutnya yakni QR. Hal ini didukung oleh Koenker (2005) yang menunjukkan bagaimana data untuk *outlier* dapat diselesaikan dengan menggunakan regresi *quantile*. Model ARIMAX efek variasi kalender yang diperoleh pada Persamaan 4.35 menghasilkan estimasi parameter dengan beberapa parameter yang tidak signifikan seperti yang terlihat pada Lampiran V. Parameter yang tidak signifikan tersebut akan tetap digunakan untuk mendapatkan nilai prediksi model ARIMAX([2,5],0,0)(1,0,0)<sup>12</sup>. Nilai prediksi tersebut akan digunakan pada tahap selanjutnya dalam peramalan *hybrid* model ARIMAX-QR

Hasil akurasi peramalan *outflow* uang kartal BI Nasional menggunakan model ARIMAX ([2,5],0,0)(1,0,0)<sup>12</sup> dapat dilihat pada Tabel 4.59

**Tabel 4.59** Akurasi Peramalan Menggunakan Model ARIMAX *Outflow* Uang Kartal BI Nasional

ARIMAX ([2,5],0,0)(1,0,0) <sup>12</sup>		
Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	6258,468	15258,200
MdAE	14936,710	8336,839

Berdasarkan akurasi peramalan *Outflow* uang kartal BI Nasional menggunakan model ARIMAX pada Tabel 4.59, maka model terbaik yang diperoleh adalah model ARIMAX ([2,5],0,0)(1,0,0)<sup>12</sup> yang telah memenuhi asumsi residual *white noise*. Model tersebut dilanjutkan pada pengujian varians residual homogen. Pendeteksian terhadap homogenitas varians dilakukan dengan cara pemeriksaan terhadap residual kuadrat dari model ARIMAX dengan efek variasi kalender dengan menggunakan uji *Lagrange Multiplier* (LM). Uji LM digunakan untuk mendeteksi adanya proses ARCH/GARCH, yaitu heterokedastisitas varians residual yang dipengaruhi oleh residual kuadrat periode

sebelumnya atau biasa disebut heterokedastisitas varians residual bersyarat (*conditional heterocedasticity*) dalam deret waktu. Hipotesis awal varians residual homogen (tidak terdapat proses ARCH/GARCH). Hasil uji LM disajikan pada Tabel 4.60.

**Tabel 4.60** Uji Heteroskedastisitas Model ARIMAX Data *Outflow* Uang Kartal BI Nasional

$k$	$t^2$	$P\text{-value}$
1	2,445	0,1178
2	3,020	0,221
3	3,615	0,306
$\vdots$	$\vdots$	$\vdots$
12	12,818	0,382

Hasil uji heterokedastisitas model menggunakan Uji LM pada Tabel 4.60 menunjukkan varians residual homogen karena ada  $p\text{-value}$  yang lebih besar dari 0,05 (  $= 5\%$ ). Sehingga model ARIMAX dengan variasi kalender *outflow* uang kartal pada Persamaan 4.58 bersifat homogen.

Tahap selanjutnya adalah melakukan peramalan dengan menggunakan *quantile regression* dimana hasil prediksi pada metode arimax diatas. Hasil estimasi parameter yang dilakukan dengan model *hybrid* ARIMAX-QR dengan efek variasi kalender yang diperoleh adalah sebagai berikut

**Tabel 4.61** Hasil Estimasi Parameter Model *hybrid* ARIMAX-QR *Outflow* Uang Kartal BI Nasional

Kuantil	Estimasi	Standar Error	T value	$P\text{-value}$
2,5%	0,572	0,016	34,911	0,000
50%	0,989	0,014	72,992	0,000
97,5%	1,459	0,019	73,521	0,000

Berdasarkan Tabel 4.61 estimasi parameter dengan menggunakan metode ARIMAX-QR untuk *outflow* uang kartal BI Nasional, menghasilkan nilai estimasi parameter yang berbeda-beda sesuai dengan nilai kuantil dari Y dimana semakin besar kuantil semakin besar pula nilai estimasinya. Hasil uji signifikansi menunjukkan bahwa nilai estimasi parameter pada setiap kuantil telah signifikan sehingga nilai Y diduga berdasarkan nilai kuantilnya. Persamaan regresi untuk kuantil 2,5%, 50%, dan 97,5% dapat dilihat pada Persamaan 4.31:

$$\begin{aligned} Y_{4t}(2,5\%) &= 0,627\hat{Z}_{4t} + a_t \\ Y_{4t}(50\%) &= 1,293\hat{Z}_{4t} + a_t \\ Y_{4t}(97,5\%) &= 1,459\hat{Z}_{4t} + a_t \end{aligned} \quad (4.31)$$

Dengan  $\hat{Z}_{4t}$  merupakan nilai prediksi model ARIMAX. Dari model *hybrid* ARIMAX-QR pada setiap kuantil ini selanjutnya akan diperoleh peramalan pada setiap kuantil yang akan di sajikan pada Tabel 4.62

**Tabel 4.62** Peramalan Menggunakan Model ARIMAX-QR untuk *Outflow* Uang Kartal Nasional


Bulan	Kuantil		
	2,5%	50%	97,5%
Januari	11847,59	20482,20	30227,56
Februari	20724,64	35828,88	52876,14
Maret	21665,11	37454,79	55275,65
April	33276,77	57529,09	84901,24
Mei	25733,45	44488,16	65655,47
Juni	67505,77	116704,40	172232
Juli	42011,88	72630,39	107187,70
Agustus	18014,80	31144,10	45962,36
September	25560,84	44189,74	65215,07
Oktober	32957,09	56976,43	84085,63
November	26465,33	45753,44	67522,77
Desember	51510,98	89052,50	131423,40

Hasil akurasi peramalan *outflow* uang kartal BI Nasional menggunakan model ARIMAX-QR pada setiap kuantil dapat dilihat pada Tabel 4.63

**Tabel 4.63** Akurasi Peramalan Menggunakan Model ARIMAX-QR untuk *Outflow* Uang Kartal BI Nasional

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	5740,498	15116,450
MdAE	3421,509	8092,902

Berdasarkan Tabel 4.63 model ARIMAX-QR menghasilkan nilai ramalan yang baik menggunakan kriteria MdAE. Secara visual peramalan *outflow* uang kartal BI Nasional dapat dilihat pada Gambar 4.17.



**Gambar 4.17** Ramalan *Out-sample* ARIMAX-QR *Outflow* Uang Kartal BI Nasional

Berdasarkan Gambar 4.17 dapat disimpulkan bahwa peramalan interval dengan menggunakan ARIMAX-QR lebih baik dibandingkan dengan peramalan interval dengan menggunakan konfiden interval. Pola data model hasil ramalan dengan menggunakan metode *hybrid* ARIMAX-QR mengikuti pola data aktual. Dalam

rentang kuantil yang diberikan model *hybrid* ARIMAX-QR mampu menangkap pola variasi kalender pada bulan Juni.

#### **4.4 Model *Hybrid* QRNN untuk *Inflow* dan *Outflow* Uang Kartal Provinsi NTT dan Nasional**

Dalam perkembangan analisis runtun waktu, telah banyak diketahui bahwa banyak fenomena yang menarik dan sederhana seringkali merupakan fenomena yang nonlinear, yaitu hubungan antara kejadian di masa lalu dan saat ini adalah nonlinear. Dengan demikian, kelompok pemodelan runtun waktu yang linear tidaklah cukup dan sesuai untuk kasus-kasus tersebut. Secara visualisasi dapat dikatakan bahwa data *Outflow* dan *Inflow* uang kartal di NTT maupun Nasional memiliki pola nonlinear. Hal ini didukung dengan nonlinearity test yang dapat dilihat pada lampiran. Dengan demikian, perlu diterapkan metode QRNN yang dapat mengurangi noise pada data *Inflow* dan *Outflow*.

##### **4.4.1 Model *Hybrid* QRNN untuk *Inflow* Uang Kartal Provinsi NTT**

Metode QRNN merupakan pengembangan dari metode *quantile regression* pada data nonlinear. Tahap awal pembentukan model QRNN mengacu pada pemodelan *Neural Network* yang memuat  $n$  input dan dikoneksikan pada  $m$  unit dalam *hidden layer*. Dalam konteks regresi, input dinyatakan sebagai variabel *explanatory* sedangkan output dinyatakan sebagai variabel dependen. White(1992) memberikan teori pendukung yang menjelaskan kegunaan *quantile regression* dalam *artificial neural network* untuk mengestimasi kekuatan model kuantil nonlinear. Dengan menggunakan teori yang ada serta konsep dasar *quantile regression* yang dikembangkan oleh Koenker dan Basset(1978,1982) maka dibentuklah model QRNN oleh J.W. Taylor pada tahun 2000. Pembentukan model QRNN diawali dengan penentuan jumlah input. Penentuan jumlah input dalam arsitektur model nonlinear ini menggunakan nilai prediksi hasil model ARIMAX sebelumnya.

Untuk mendapatkan arsitektur QRNN optimal dilakukan kombinasi pengujian 1,2,3,4,5,10 dan 15 *hidden neuron* dengan maksimum iterasi 5000.

Selanjutnya akan dianalisis model QRNN dengan menggunakan nilai prediksi sebagai *input*, dengan jumlah neuron pada hidden layer sebanyak 1,2,3,4,5,10 dan 15 *hidden neuron*. Hasil analisis model QRNN pada setiap neuron dapat dilihat pada Tabel 4.64

**Tabel 4.64** Perbandingan Akurasi Peramalan Menggunakan QRNN


Banyaknya Neuron	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	66,190	<b>129,801</b>	38,628	<b>58,476</b>
2	66,314	352,437	38,624	71,329
3	67,924	258,946	36,509	71,130
4	66,127	341,624	34,395	70,081
5	62,616	1393,170	35,950	71,318
10	58,661	6098,180	31,818	68,932
15	53,760	348,444	32,045	84,842

Berdasarkan Tabel 4.64 nilai RMSE dan MdAE model QRNN dapat bervariasi pada setiap input dan neuron. Pada hasil ramalan RMSE *in-sample* terlihat bahwa 1 input 15 neuron memberikan nilai akurasi ramalan yang relatif kecil dibandingkan jumlah neuron lain. Sebaliknya pada hasil ramalan RMSE *out-sample*, 1 input 1 neuron memberikan nilai akurasi ramalan yang relatif lebih kecil dari jumlah neuron lain. Hal yang sama terjadi pula dengan kriteria MdAE. Pada kriteria MdAE, 1 input 10 neuron memberikan nilai akurasi ramalan yang relatif lebih kecil dari jumlah neuron lain pada data *in-sample*. Sedangkan pada data *out-sample*, nilai akurasi terkecil diperoleh pada 1 input dan 1 neuron. Memilih model dengan jumlah neuron yang menghasilkan ramalan terbaik adalah sangat penting. Mengingat tujuan dari penelitian ini adalah untuk memperoleh ramalan terbaik maka akan diambil nilai terkecil pada data *out-sample* dengan kriteria MdAE. Hal ini dikarenakan MdAE merupakan salah satu kriteria akurasi peramalan berbasis median. Dengan demikian akan dipilih 1 input dan 1 *hidden neuron* sebagai model yang terbaik. Selanjutnya akan diperoleh model *hybrid*

QRNN dengan 1 input dan 1 *hidden neuron* pada kuantil 2,5, 50% dan 97,5% seperti yang terlihat pada Persamaan 4.32:

$$\begin{aligned} Y_{1t}(2,5\%) &= -10,400 + 271,819 \tanh(0,5 \times (0,069 + 0,001 \hat{Z}_{1t})) + a_t \\ Y_{1t}(50\%) &= 1886,618 + 1889,325 \tanh(0,5 \times (-7,273 + 0,230 \hat{Z}_{1t})) + a_t \\ Y_{1t}(97,5\%) &= -7,918 + 19,718 \tanh(0,5 \times (0,983 + 0,157 \hat{Z}_{1t})) + a_t \end{aligned} \quad (4.32)$$

Bentuk *architecture* model *hybrid QRNN* dengan 1 input dan 1 *hidden neuron* dapat dilihat pada Gambar 4.18



**Gambar 4.18** *Architecture* model *hybrid QRNN* dengan 1 input dan 1 *hidden neuron* untuk *Inflow* Uang Kartal Provinsi NTT

Dengan model *hybrid QRNN* pada setiap kuantil ini selanjutnya akan diperoleh peramalan pada setiap kuantil yang akan di sajikan pada Tabel 4.65

**Tabel 4.65** Peramalan Menggunakan Model *hybrid QRNN* untuk *Inflow* Uang Kartal BI Provinsi NTT


Bulan	Kuantil		
	2,5%	50%	97,5%
Januari	225,436	1329,892	1130,699
Februari	123,652	415,458	668,003
Maret	100,342	302,861	532,762
April	67,827	181,696	325,734
Mei	67,357	180,203	322,593
Juni	66,731	178,223	318,397
Juli	123,143	412,730	665,172
Agustus	93,178	272,914	488,970
September	76,563	210,717	383,417
Oktober	66,447	177,327	316,489
November	69,479	187,005	336,759
Desember	69,028	185,546	333,750

Hasil akurasi peramalan *inflow* uang kartal BI Provinsi NTT menggunakan model *hybrid* QRNN pada setiap kuantil dapat dilihat pada Tabel 4.66

**Tabel 4.66** Akurasi Peramalan Menggunakan Model *Hybrid* QRNN untuk *Inflow* Uang Kartal BI Provinsi NTT

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	66,442	129,801
MdAE	38,628	58,476

Berdasarkan Tabel 4.66 model *hybrid* QRNN menghasilkan nilai ramalan yang baik menggunakan kriteria MdAE. Secara visual peramalan *inflow* uang kartal BI Provinsi NTT dapat dilihat pada Gambar 4.19 berikut



**Gambar 4.19** Ramalan Interval *Out-sample* QRNN *Inflow* Uang Kartal BI Provinsi NTT

Berdasarkan Gambar 4.19 dapat dilihat bahwa ramalan dari model *hybrid* QRNN belum mampu mendekati nilai aktual pada bulan Januari. Hal ini di mungkinkan adanya outlier pada bulan tersebut yang tidak bisa diatasi dengan model QRNN

#### 4.3.2 Model *Hybrid* QRNN untuk *Outflow* Uang Kartal Provinsi NTT

Pembentukan model QRNN untuk *outflow* uang kartal diawali dengan penentuan jumlah input. Pembentukan model QRNN diawali dengan penentuan jumlah input. Penentuan jumlah input dalam arsitektur model nonlinear ini



menggunakan nilai prediksi hasil model ARIMAX *outflow* uang kartal BI Provinsi NTT sebelumnya. Untuk mendapatkan arsitektur QRNN optimal dilakukan kombinasi pengujian 1,2,3,4,5,10 dan 15 *hidden neuron* dengan maksimum iterasi 5000. Selanjutnya akan dianalisis model QRNN dengan menggunakan nilai prediksi sebagai *input*, dengan jumlah neuron pada *hidden layer* sebanyak 1,2,3,4,5,10 dan 15 neuron. Hasil analisis model QRNN pada setiap neuron dapat dilihat pada Tabel 4.67

**Tabel 4.67** Perbandingan Akurasi Peramalan Menggunakan QRNN


Banyaknya Neuron	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	94,651	189,955	52,094	96,676
2	96,356	229,813	51,309	96,767
3	95,101	<b>99,009</b>	51,102	83,414
4	96,006	215,725	49,397	86,048
5	92,556	406,105	51,791	<b>82,287</b>
10	89,459	189,850	46,199	86,430
15	87,576	437,996	44,111	155,849

Berdasarkan Tabel 4.67 nilai RMSE dan MdAE model QRNN dapat bervariasi pada setiap input dan neuron. Pada hasil ramalan RMSE *in-sample* terlihat bahwa 1 input 15 neuron memberikan nilai akurasi ramalan yang relatif kecil dibandingkan jumlah neuron lain. Sebaliknya pada hasil ramalan RMSE *out-sample*, 1 input 3 neuron memberikan nilai akurasi ramalan yang relatif lebih kecil dari jumlah neuron lain. Hal yang sama terjadi pula dengan kriteria MdAE. Pada kriteria MdAE, 1 input 15 neuron memberikan nilai akurasi ramalan yang relatif lebih kecil dari jumlah neuron lain pada data *in-sample*. Sedangkan pada data *out-sample*, nilai akurasi terkecil diperoleh pada 1 input dan 5 neuron. Memilih model dengan jumlah neuron yang menghasilkan ramalan terbaik adalah sangat penting. Mengingat tujuan dari penelitian ini adalah untuk memperoleh ramalan terbaik maka akan diambil nilai terkecil pada data *out-sample* dengan

kriteria RMSE dan MdAE. Dengan demikian akan dipilih 1 input dan 3 *hidden neuron* sebagai model yang terbaik. Selanjutnya akan diperoleh model *hybrid QRNN* dengan 1 input dan 3 *hidden neuron* pada kuantil 2,5%, 50% dan 97,5% seperti yang terlihat pada Persamaan 4.32:

$$\begin{aligned}
 Y_{2t}(25\%) &= 2,524 - 0,402 \tanh(0,5 \times (23,592 - 63,057 \hat{Z}_{2t})) + \\
 &\quad 1,414 \tanh(0,5 \times (-12,611 + 4,155 \hat{Z}_{2t})) + \\
 &\quad 9,167 \tanh(0,5 \times (-0,342 + 0,050 \hat{Z}_{2t})) + a_t \\
 Y_{2t}(50\%) &= 1,324 - 11,507 \tanh(0,5 \times (-0,221 + 4,110 \hat{Z}_{2t})) + \\
 &\quad 1,398 \tanh(0,5 \times (-5,245 + 2,257 \hat{Z}_{2t})) + \\
 &\quad 12,522 \tanh(0,5 \times (-0,190 + 3,785 \hat{Z}_{2t})) + a_t \\
 Y_{2t}(97,5\%) &= 2,438 - 0,655 \tanh(0,5 \times (-2,271 - 4,228 \hat{Z}_{2t})) + \\
 &\quad 1,711 \tanh(0,5 \times (-6,672 + 2,118 \hat{Z}_{2t})) + \\
 &\quad 0,567 \tanh(0,5 \times (-77,109 - 72,942 \hat{Z}_{2t})) + a_t
 \end{aligned} \tag{4.33}$$

Bentuk *architecture* model *hybrid QRNN* dengan 1 input dan 3 *hidden neuron* dapat dilihat pada Gambar 4.20



**Gambar 4.20** *Architecture* model *hybrid QRNN* untuk *Outflow NTT*

Dari model *hybrid QRNN* pada setiap kuantil ini selanjutnya akan diperoleh peramalan pada setiap kuantil yang akan di sajikan pada Tabel 4.68:

**Tabel 4.68** Peramalan Menggunakan Model *hybrid* QRNN untuk *Outflow* Uang Kartal BI Provinsi NTT


Bulan	Kuantil		
	2,5%	50%	97,5%
Januari	56,165	154,987	320,885
Februari	163,712	314,015	490,242
Maret	65,422	208,606	376,845
April	84,789	326,477	504,435
Mei	74,229	262,252	426,339
Juni	925,651	917,181	940,185
Juli	660,966	574,420	815,505
Agustus	58,799	330,129	505,568
September	237,173	470,656	517,771
Oktober	244,668	430,074	515,448
November	558,768	551,334	808,289
Desember	2120,850	1252,920	1656,340

Hasil akurasi peramalan *outflow* uang kartal BI Provinsi NTT menggunakan model *hybrid* QRNN setiap kuantil dapat dilihat pada Tabel 4.69

**Tabel 4.69** Akurasi Peramalan Menggunakan Model *Hybrid* QRNN untuk *Outflow* Uang Kartal BI Provinsi NTT

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	95,463	99,009
MdAE	51,102	83,414

Berdasarkan Tabel 4.69 model *hybrid* QRNN menghasilkan nilai ramalan terkecil menggunakan kriteria MdAE. Secara visual peramalan *outflow* uang kartal BI Provinsi NTT dapat dilihat pada Gambar 4.30 berikut



**Gambar 4.21** Ramalan Interval *Out-sample* QRNN *Outflow* Uang Kartal BI Provinsi NTT

Berdasarkan Gambar 4.21 dapat dilihat bahwa ramalan dari model *hybrid* QRNN sudah mampu mendekati nilai aktual namun hasil ramalan interval tersebut belum memberikan hasil yang memuaskan karena pada bulan Juni dan November nilai aktual masih berada di luar interval. Hal ini di mungkinkan adanya variabel *dummy* yang tidak bisa diatasi dengan model QRNN.

#### 4.3.3 Model *Hybrid* QRNN untuk *Inflow* Uang Kartal Nasional

Tahap awal pembentukan model QRNN mengacu pada pemodelan *Neural Network* yang memuat  $n$  input dan dikoneksikan pada  $m$  unit dalam *hidden layer*. Dalam konteks regresi, input dinyatakan sebagai variabel *explanatory* sedangkan output dinyatakan sebagai variabel dependen. White (1992) memberikan teori pendukung yang menjelaskan kegunaan *quantile regression* dalam *artificial neural network* untuk mengestimasi kekuatan model kuantil nonlinear. Dengan menggunakan teori yang ada serta konsep dasar *quantile regression* yang dikembangkan oleh Koenker dan Basset (1978, 1982) maka dibentuklah model QRNN oleh J.W. Taylor pada tahun 2000. Pembentukan model QRNN diawali dengan penentuan jumlah input. Penentuan jumlah input dalam arsitektur model nonlinear ini menggunakan nilai prediksi hasil model ARIMAX sebelumnya.

Untuk mendapatkan arsitektur QRNN optimal dilakukan kombinasi pengujian 1,2,3,4,5,10 dan 15 *hidden neuron* dengan maksimum iterasi 5000. Selanjutnya akan dianalisis model QRNN dengan menggunakan nilai prediksi

Model ARIMAX *inflow* uang Kartal BI Nasional sebagai *input*, dengan jumlah neuron pada *hidden layer* sebanyak 1,2,3,4,5,10 dan 15 *hidden neuron*. Hasil analisis model QRNN pada setiap neuron dapat dilihat pada Tabel 4.70


**Tabel 4.70** Perbandingan Akurasi Peramalan Menggunakan QRNN

Banyaknya Neuron	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	5999,6	14142,9	2822,3	<b>9002,7</b>
2	6279	11920,3	2297,3	10140
3	6279,2	11909,8	2297,2	10123
4	6305,3	11553,9	2254,2	10064
5	6081,1	<b>11340,1</b>	2311,5	10244
10	4678,9	55921,8	2188,9	9625,6
15	4595,8	22450,7	2102,2	10380

Berdasarkan Tabel 4.70 nilai RMSE dan MdAE model QRNN dapat bervariasi pada setiap input dan neuron. Pada hasil ramalan RMSE *in-sample* terlihat bahwa 1 input 15 neuron memberikan nilai akurasi ramalan yang relatif kecil dibandingkan jumlah neuron lain. Sebaliknya pada hasil ramalan RMSE *out-sample*, 1 input 5 neuron memberikan nilai akurasi ramalan yang relatif lebih kecil dari jumlah neuron lain. Hal yang sama terjadi pula dengan kriteria MdAE. Pada kriteria MdAE, 1 input 15 neuron memberikan nilai akurasi ramalan yang relatif lebih kecil dari jumlah neuron lain pada data *in-sample*. Sedangkan pada data *out-sample*, nilai akurasi terkecil diperoleh pada 1 input dan 1 neuron. Memilih model dengan jumlah neuron yang menghasilkan ramalan terbaik adalah sangat penting. Mengingat tujuan dari penelitian ini adalah untuk memperoleh ramalan terbaik maka akan diambil nilai terkecil pada data *out-sample* dengan kriteria RMSE dan MdAE. Dengan demikian akan dipilih 1 input dan 5 *hidden neuron* sebagai model yang terbaik. Selanjutnya akan diperoleh model *hybrid QRNN* dengan 1 input dan 5 *hidden neuron* pada kuantil 2,5%, 50% dan 97,5% seperti yang terlihat pada Persamaan 4.32:

$$\begin{aligned}
Y_{3t}(2,5\%) &= 12,873 + 0,352 \tanh(0,5 \times (-5,433 - 6,107 \hat{Z}_{3t})) \\
&\quad + 8,365 \tanh(0,5 \times (11,158 - 3,955 \hat{Z}_{3t})) \\
&\quad - 26,993 \tanh(0,5 \times (4,242 - 1,163 \hat{Z}_{3t})) \\
&\quad + 4,361 \tanh(0,5 \times (3,839 - 1,663 \hat{Z}_{3t})) \\
&\quad - 0,256 \tanh(0,5 \times (-12,547 - 12,805 \hat{Z}_{3t})) \\
&\quad + a_t \\
Y_{3t}(50\%) &= -0,085 - 5,717 \tanh(0,5 \times (-19,643 + 4,854 \hat{Z}_{3t})) + \\
&\quad 16,440 \tanh(0,5 \times (-1,315 - 2,218 \hat{Z}_{3t})) \\
&\quad - 17,433 \tanh(0,5 \times (0,374 - 0,188 \hat{Z}_{3t})) \\
&\quad - 1,964 \tanh(0,5 \times (19,340 - 6,384 \hat{Z}_{3t})) \\
&\quad - 14,654 \tanh(0,5 \times (-1,440 - 2,443 \hat{Z}_{3t})) \\
&\quad + a_t \\
Y_{3t}(97,5\%) &= 0,371 - 0,653 \tanh(0,5 \times (-6,488 + 11,669 \hat{Z}_{3t})) \\
&\quad - 11,954 \tanh(0,5 \times (2,601 + 2,146 \hat{Z}_{3t})) \\
&\quad + 8,416 \tanh(0,5 \times (8,416 + 2,967 \hat{Z}_{3t})) \\
&\quad - 5,293 \tanh(0,5 \times (0,725 - 1,010 \hat{Z}_{3t})) \\
&\quad + 3,915 \tanh(0,5 \times (4,904 + 2,013 \hat{Z}_{3t})) \\
&\quad + a_t
\end{aligned} \tag{4.32}$$

Bentuk *architecture* model *hybrid* QRNN dengan 1 input dan 3 *hidden neuron* dapat dilihat pada Gambar 4.22



**Gambar 4.22** *Architecture* model *hybrid* QRNN untuk *Inflow* Nasional

Dari model *hybrid* QRNN pada setiap kuantil ini selanjutnya akan diperoleh peramalan pada setiap kuantil yang akan di sajikan pada Tabel 4.71

**Tabel 4.71** Peramalan Menggunakan Model *hybrid* QRNN untuk *Inflow* Uang Kartal BI Nasional


Bulan	Kuantil		
	2,5%	50%	97,5%
Januari	49657,100	56095,800	74166,200
Februari	23672,100	33832,700	38117,300
Maret	19589,400	30807	35208,500
April	21033,200	31823,700	34834,400
Mei	17871,600	29696,900	38308,500
Juni	18486,800	30081,100	37047,800
Juli	5003,720	93375,300	92810,400
Agustus	36787,100	44660,400	58684,600
September	18305,500	29966,300	37423
Oktober	21998,700	32539,400	35673,700
November	16702,600	29007,600	39926,800
Desember	14545,600	27828,900	38705

Hasil akurasi peramalan *inflow* uang kartal BI Nasional menggunakan model *hybrid* QRNN pada setiap kuantil dapat dilihat pada Tabel 4.72

**Tabel 4.72** Akurasi Peramalan Menggunakan Model *Hybrid* QRNN untuk *Inflow* Uang Kartal BI Nasional

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	6022,488	11340,110
MdAE	2311,472	10244,160

Berdasarkan Tabel 4.72 model *hybrid* QRNN menghasilkan nilai ramalan yang baik menggunakan kriteria MDAE. Secara visual peramalan *inflow* uang kartal BI Provinsi NTT dapat dilihat pada Gambar 4.23 berikut



**Gambar 4.23** Ramalan Interval *Out-sample* ARIMAX-QR *Inflow* Uang Kartal BI Nasional

Berdasarkan Gambar 4.31 dapat dilihat bahwa ramalan dari model *hybrid* QRNN belum mampu mendekati nilai aktual. Hasil ramalan interval tersebut memberikan hasil yang belum memuaskan karena pada bulan Januari, Februari, Maret, Mei, Juli, September dan Oktober masih berada di luar interval. Hal ini di mungkinakan adanya variabel outlier yang tidak bisa diatasi dengan model QRNN.

#### 4.3.3 Model *Hybrid* QRNN untuk *Outflow* Uang Kartal BI Tingkat Nasional

Tahap awal pembentukan model QRNN mengacu pada pemodelan *Neural Network* yang memuat  $n$  input dan dikoneksikan pada  $m$  unit dalam *hidden layer*. Dalam konteks regresi, input dinyatakan sebagai variabel *explanatory* sedangkan output dinyatakan sebagai variabel dependen. White(1992) memberikan teori pendukung yang menjelaskan kegunaan *quantile regression* dalam *artificial neural network* untuk mengestimasi kekuatan model kuantil nonlinear. Dengan menggunakan teori yang ada serta konsep dasar *quantile regression* yang dikembangkan oleh Koenker dan Basset(1978, 1982) maka dibentuklah model QRNN oleh J.W. Taylor pada tahun 2000. Pembentukan model QRNN diawali



dengan penentuan jumlah input. Penentuan jumlah input dalam arsitektur model nonlinear ini menggunakan nilai prediksi hasil model ARIMAX *outflow* uang kartal BI Nasional.

Untuk mendapatkan arsitektur QRNN optimal dilakukan kombinasi pengujian 1,2,3,4,5,10 dan 15 *hidden neuron* dengan maksimum iterasi 5000. Selanjutnya akan dianalisis model QRNN dengan menggunakan nilai prediksi sebagai *input*, dengan jumlah neuron pada hidden layer sebanyak 1,2,3,4,5,10 dan 15 *hidden neuron*. Hasil analisis model QRNN pada setiap neuron dapat dilihat pada Tabel 4.73

**Tabel 4.73** Perbandingan Akurasi Peramalan Menggunakan QRNN


Banyaknya Neuron	RMSE		MdAE	
	<i>In-sample</i>	<i>Out-sample</i>	<i>In-sample</i>	<i>Out-sample</i>
1	5615,027	<b>14786,960</b>	3339,649	<b>8993,816</b>
2	5399,523	15035,870	3027,196	10236,420
3	5397,988	15139,130	3036,082	10283,840
4	5399,9110	15095,080	3022,232	10252,580
5	5359,668	17221,400	2668,254	12264,280
10	5051,577	24443,720	2600,289	11280,610
15	<b>4988,827</b>	17020,230	<b>2226,881</b>	11269,160

Berdasarkan Tabel 4.73 nilai RMSE dan MdAE model QRNN dapat bervariasi pada setiap input dan neuron. Pada hasil ramalan RMSE *in-sample* terlihat bahwa 1 input 15 neuron memberikan nilai akurasi ramalan yang relatif kecil dibandingkan jumlah neuron lain. Sebaliknya pada hasil ramalan RMSE *out-sample*, 1 input 1 neuron memberikan nilai akurasi ramalan yang relatif lebih kecil dari jumlah neuron lain. Hal yang sama terjadi pula dengan kriteria MdAE. Pada kriteria MdAE, 1 input 15 neuron memberikan nilai akurasi ramalan yang relatif lebih kecil dari jumlah neuron lain pada data *in-sample*. Sedangkan pada data *out-sample*, nilai akurasi terkecil diperoleh pada 1 input dan 1 neuron.

Memilih model dengan jumlah neuron yang menghasilkan ramalan terbaik adalah sangat penting. Mengingat tujuan dari penelitian ini adalah untuk memperoleh ramalan terbaik maka akan diambil nilai terkecil pada data *out-sample* dengan kriteria MdAE. Hal ini dikarenakan MdAE merupakan salah satu kriteria akurasi peramalan berbasis median. Dengan demikian akan dipilih 1 input dan 1 *hidden neuron* sebagai model yang terbaik. Selanjutnya akan diperoleh model *hybrid QRNN* dengan 1 input dan 1 *hidden neuron* pada kuantil 2,5%, 50% dan 97,5% seperti yang terlihat pada Persamaan 4.32:

$$\begin{aligned} Y_{4t}(2,5\%) &= 3,689 + 5,841 \tanh(0,5 \times (-1,941 + 0,492 \hat{Z}_{4t})) a_t \\ Y_{4t}(50\%) &= 32,752 + 55,126 \tanh(0,5 \times (-1,369 - 0,053 \hat{Z}_{4t})) + a_t \\ Y_{4t}(97,5\%) &= 1,654 + 3,113 \tanh(0,5 \times (-0,788 + 0,824 \hat{Z}_{4t})) + a_t \end{aligned} \quad (4.32)$$

Bentuk *architecture* model *hybrid QRNN* dengan 1 input dan 1 *hidden neuron* dapat dilihat pada Gambar 4.24



**Gambar 4.24** Architecture model *hybrid QRNN* untuk *Outflow* Nasional

Dari model *hybrid QRNN* pada setiap kuantil ini selanjutnya akan diperoleh peramalan pada setiap kuantil yang akan di sajikan pada Tabel 4.74

**Tabel 4.74** Peramalan Menggunakan Model *hybrid* QRNN untuk *Inflow* Uang Kartal BI Provinsi NTT


Bulan	Kuantil		
	2,5%	50%	97,5%
Januari	10661,41	20291,28	29753,79
Februari	20610,52	35292,88	47077,18
Maret	21847,14	36904,69	49148,41
April	40304,16	57159,96	75672,92
Mei	27631,93	43926,71	58404,06
Juni	121848,8	120678,8	117652,5
Juli	58124,98	72830,16	93015,09
Agustus	17250,69	30672,79	41322,32
September	27371,83	43627,14	58004,89
Oktober	39715,01	56593,53	74966,26
November	28749,41	45198,51	60099,49
Desember	80725,37	90291,73	106376,9

Hasil akurasi peramalan *inflow* uang kartal BI Provinsi NTT menggunakan model *hybrid* QRNN pada setiap kuantil dapat dilihat pada Tabel 4.75

**Tabel 4.75** Akurasi Peramalan Menggunakan Model *Hybrid* QRNN untuk *Outflow* Uang Kartal BI Nasional

Kriteria	<i>In-sample</i>	<i>Out-sample</i>
RMSE	5636,418	14786,960
MdAE	3339,649	8993,817

Berdasarkan Tabel 4.75 model *hybrid* QRNN menghasilkan nilai ramalan yang baik menggunakan kriteria MdAE. Secara visual peramalan *outflow* uang kartal BI Nasional dapat dilihat pada Gambar 4.29 berikut



**Gambar 4.25** Ramalan Interval *Out-sample* QRNN *Outflow* Uang Kartal BI Nasional

Berdasarkan Gambar 4.32 dapat dilihat bahwa ramalan dari model *hybrid* QRNN mampu mendekati nilai aktual. Hasil ramalan interval tersebut belum memberikan hasil yang memuaskan karena pada bulan Juni dan Juli, nilai aktual masih berada di luar ramalan interval. Hal ini di mungkinkan adanya outlier pada bulan tersebut yang tidak bisa diatasi dengan model QRNN

#### 4.5 Pemilihan Model Terbaik Untuk *Inflow* dan *Outflow* Uang Kartal BI

Setelah melakukan pemodelan *inflow* dan *outflow* uang kartal BI di tingkat provinsi NTT maupun Nasional dengan beberapa metode, maka pada tahap ini akan dipilih metode terbaik yang digunakan dengan membandingkan nilai dari kriteria RMSE dan MdAE *in-sample* dan *out-sample* dari beberapa model *time series* yang telah didapatkan. Hasil kriteria RMSE dan MdAE *in-sample* beserta nilai standard deviasi dari data *in-sample* dapat dilihat pada Tabel 4.76

**Tabel 4.76** Perbandingan RMSE dan MdAE *In-sample* Tiap Metode

Kriteria RMSE				
Data <i>In-sample</i>	Standard Deviasi	Metode		
		ARIMAX	ARIMAX-QR	QRNN
<i>Inflow</i> NTT	146	79,349	73,552	<b>66,442</b>
<i>Outflow</i> NTT	267.9	106,095	97,779	<b>95,463</b>
<i>Inflow</i> Nasional	17208	7203,483	6676,233	<b>6022,488</b>
<i>Outflow</i> Nasional	21594	6258,468	5740,498	<b>5636,418</b>
Kriteria MdAE				
<i>Inflow</i> NTT	146	<b>37,288</b>	41,003	38,628
<i>Outflow</i> NTT	267.9	<b>50,372</b>	51,328	51,102
<i>Inflow</i> Nasional	17208	3179,188	3102,838	<b>2311,472</b>
<i>Outflow</i> Nasional	21594	14936,71	3421,509	<b>3339,649</b>

Berdasarkan kriteria RMSE dan MdAE *in-sample* pada tabel diatas, model ARIMAX memperoleh nilai ramalan terbaik untuk data *inflow* dan *outflow* NTT berdasarkan kriteria MdAE sedangkan model QRNN memperoleh nilai terbaik untuk data *inflow* dan *outflow* uang kartal BI Nasional berdasarkan pada kriteria MdAE. Secara umum semua metode memperoleh nilai *in-sample* yang lebih kecil dibandingkan dengan nilai standar deviasi *in-sample*, hal ini menunjukkan bahwa model yang dibangun dengan berbagai metode layak digunakan untuk peramalan.

Berdasarkan kriteria *out-sample* pada Tabel 4.77, model terbaik untuk *inflow* dan *outflow* uang kartal BI di tingkat Provinsi NTT masing-masing adalah ARIMAX dan QRNN. Sedangkan model terbaik untuk *inflow* dan *outflow* uang kartal BI di tingkat Nasional adalah QRNN. Karena kesimpulan model terbaik untuk *inflow* dan *outflow* uang kartal hampir sama antara *in-sample* dan *out-sample*, yaitu model ARIMAX untuk *in-sample* data *inflow* dan *outflow* uang kartal BI provinsi NTT dan model QRNN untuk *in-sample* data *inflow* dan *outflow* uang kartal BI Nasional maka dalam penelitian ini digunakan model


terbaik adalah ARIMAX untuk data inflow uang kartal BI Provinsi NTT sedangkan QRNN untuk data lainnya. Hal ini sejalan dengan hasil studi simulasi dan eksplorasi data *Inflow* dan *outflow* untuk data yang bersifat homogen linear dan heterogen nonlinear.

**Tabel 4.77** Perbandingan RMSE dan MdAE *Out-Sample* Tiap Metode


Kriteria RMSE				
Data <i>Out-sample</i>	Standard Deviasi	Metode		
		ARIMAX	ARIMAX-QR	QRNN
<i>Inflow</i> NTT	211	<b>59,861</b>	71,437	129,801
<i>Outflow</i> NTT	376	112,309	111,594	<b>99,009</b>
<i>Inflow</i> Nasional	22275	15486,4	16539,97	<b>11340,110</b>
<i>Outflow</i> Nasional	31623	15258,2	15116,45	<b>14786,96</b>
Kriteria MdAE				
<i>Inflow</i> NTT	211	<b>36,122</b>	54,146	58,476
<i>Outflow</i> NTT	376	96,00555	91,563	<b>83,414</b>
<i>Inflow</i> Nasional	22275	<b>6489,097</b>	7575,921	10244,160
<i>Outflow</i> Nasional	31623	8336,839	<b>8092,902</b>	8993,818

Untuk mengetahui kemampuan metode terbaik dalam melakukan peramalan maka dicari RMSE aditif dari model terbaik pada masing-masing data. Berdasarkan pemodelan yang dilakukan menggunakan metode ARIMAX, *hybrid* ARIMAX-QR dan QRNN, model ARIMAX dan QRNN terpilih sebagai model terbaik. Perbandingan hasil RMSE aditif setiap bulan untuk  $k$  langkah kedepan dilihat pada Gambar 4.33. Berdasarkan Gambar 4.26 terlihat bahwa ramalan untuk data inflow uang kartal BI NTT dengan metode ARIMAX bagus 12 tahap kedepan, ramalan untuk data outflow uang kartal BI NTT dengan metode QRNN bagus untuk 4 tahap kedepan, ramalan untuk data inflow uang kartal BI Nasional dengan metode QRNN bagus untuk 12 tahap kedepan dan ramalan untuk data

outflow uang kartal BI Nasional dengan metode QRNN bagus untuk 5 tahap kedepan. Adapun perbandingan ramalan semua metode dengan data aktual dapat dilihat pada Gambar 4.27



Gambar 4.26 RMSE Aditif  $k$  Langkah Kedepan



Gambar 4.27 Perbandingan Ramalan tiap Metode

## **BAB 5**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan penelitian yang dilakukan, diperoleh beberapa kesimpulan berikut ini yakni

1. Model terbaik untuk meramalkan *inflow* dan *outflow* uang kartal BI provinsi NTT berdasarkan kriteria RMSE dan MdAE *out-sample* masing-masing adalah model ARIMAX dan QRNN. Sedangkan untuk meramalkan *inflow* dan *outflow* uang kartal BI Nasional berdasarkan kriteria RMSE dan MdAE adalah model QRNN.
2. Nilai RMSE *out-sample* yang diperoleh untuk data *inflow* dan *outflow* uang kartal BI Provinsi NTT sebesar 36,122 dan 83,414. Sedangkan nilai MdAE *out-sample* untuk *inflow* dan *outflow* uang kartal BI Nasional sebesar 11340,110 dan 14786,96.
3. Ramalan *inflow* Provinsi NTT tertinggi pada tahun 2016 terjadi pada bulan Juli sebesar 425,599 juta rupiah dan ramalan *outflow* Provinsi NTT tertinggi terjadi pada bulan Desember sebesar 1252,92 juta rupiah. Sedangkan hasil ramalan pada tahun 2016 untuk *inflow* uang kartal Nasional tertinggi pada bulan Juli sebesar 93375,3 miliar rupiah dan ramalan *outflow* tertinggi terjadi pada bulan Juni sebesar 120679 miliar rupiah. Hal ini sejalan dengan eksplorasi data bahwa adanya variasi kalender sangat berpengaruh terhadap *inflow* dan *outflow* uang kartal.

#### **5.2 Saran**

Pada penelitian ini tidak memperhatikan hubungan *inflow* dan *outflow* secara ekonomi, sehingga pada penelitian selanjutnya disarankan untuk memperhatikan hubungan *inflow* dan *outflow* secara ekonomi. Replikasi yang dicobakan pada studi simulasi untuk analisis selanjutnya sebaiknya dilakukan replikasi untuk masing-masing ukuran sample kecil dan besar. Perlu adanya deteksi outlier pada untuk memperoleh hasil yang lebih akurat.



*“Halaman ini sengaja dikosongkan”*

## DAFTAR PUSTAKA

- Ahmad, I. S., Setiawan, Suhartono, dan Masun, N. H., (2015), "Forecasting of monthly inflow and outflow currency using time series regression and ARIMAX: The Idul Fitri effect", *AIP Conference Proceeding*, 1691, 050002.
- Arunraj, N. S., dan Ahrens, D., (2015), "A Hybrid Seasonal Autoregressive Integrated Moving Average and Quantile Regression for Daily Food Sales Forecasting", *International Journal Production Economics*, 170, hal. 321-335
- Bank Indonesia, (2016a), *Metadata: Currency in Circulation*. Diakses 7 Maret - 2016, Web Site Bank Indonesia
- Bank Indonesia, (2016b), *Statistik Sistem Pembayaran*. Diakses 14 Maret 2016, Web Site Bank Indonesia : <http://www.bi.go.id/id/statistik/sistem-pembayaran/indikator-pengedaran-uang/Contents/Default.aspx>
- Bowerman, B. L., dan O'Connel, R. T., (1993), *Forecasting and time series: An applied approach* (3rd ed.), Duxbury press, hal. 570-574.
- Canon, A. J.,(2011), "Quantile Regression Neural Network: Implementasi in R and Application to Precipitation Downscaling", *Computer and Geosciences*, 37, hal. 1277-1284.
- Cryer, J. D., dan Chan, K. S., (2008), *Time series analysis: with applications in R* (2nd ed.), Springer.
- Chatfield, C., (2000), *Time-Series Forecasting*. CRC Press, United States, hal.186.
- Demuth, Howard., dan Beale, Mark., (2002), *Neural Network Toolbox User's Guide* (4nd ed). *The MathWorks, Inc.*
- Faraway, J., dan Chatfield, C., (1998), "Time series forecasting with neural networks: a comparative study using the airline data", *Applied Statistics*, hal. 231-250.
- Fauset, L., (1994), *Fundamentals of Neural Network: Architectures, Algorithms, and Application*, Prentice-Hall, Inc., New Jersey.

- Gardner, E.S., (1988), "A Simple Method of Computing Prediction Intervals for Time Series Forecasts", *Management Science*, Vol 34, No 4, hal. 541-546
- Haykin, S., (1999), *Neural Network: A Comprehensive Foundation* (2nd ed), Prentice Hall, New Jersey.
- Hyndman, R. J., (2006), "Another Look at Measures of Forecast Accuracy", *International Journal of Forecasting*, 22, hal. 679– 688.
- Konker, R., dan Bassett, G., (1982), "Robust Test for Heteroscedasticity Based on Regression Quantiles", *Journal of The Econometric Society*, Vol 50, No. 1, hal. 43-61
- Koenker, R., dan Hallock, K. F., (2001), "Quantile Regression", *Journal of Economic Perspective*, Vol. 15, No.4, hal. 143-156.
- Koenker, R., (2005), *Quantile Regression*. Econometric society monographs. Cambridge University, New York.
- Lee, M. H., Suhartono, dan Hamzah, N. A., (2010), "Calendar variation model based on ARIMAX for forecasting sales data with Ramadhan effect", *Proceedings of the Regional Conference on Statistical Sciences 2010 (RCSS'10)*, hal. 349-361.
- Liu, L. M., (1986), "Identification of time series models in the presence of calendar variation" *International Journal of Forecasting*, Vol 2. No. 3, hal. 357-372.
- Pramono, B., Yanuarti, T., Purusitawati, P. D., dan Emmy, Y. T., s(2006), "Dampak Pembayaran Non Tunai Terhadap Perekonomian dan Kebijakan Moneter", Bank Indonesia.
- Reganata, G. P., dan Suhartono., (2016), "Inflow and outflow forecasting of currency using multi-input transfer function", *Proceedings IConSSE*, hal. 53.
- Sarle, W. S., (1994), "Neural Network and Statistical Models", *Proceedings of the Nineteenth Annual SAS Users Group International Conference*, USA. hal. 3
- Setiawan, Suhartono, Ahmad, I. S., dan Rahmawati, N. I., (2015), "Configuring calendar variation based on time series regression method for forecasting of monthly currency inflow and outflow in Central Java", *AIP Conference Proceeding*, 1691, 050024.

- Seyyed, F. J., Abraham, dan Al-Hajji, M., (2005), "Seasonality in stock returns and volatility: The Ramadan effect.", *Research in International Business and Finance*, Vol. 19, No.3, hal. 374-383.
- Suhartono, dan Lee, M. H., (2011), "Two levels regression modeling of trading day and holiday effects for forecasting retail data", *Proceeding of the 7th IMT-GT International Conference on Mathematics, Statistics and its Applications (ICMSA 2011)*, hal. 150-164.
- Suhartono, Lee, M. H., dan Prastyo, D. D., (2015), "Two levels ARIMAX and regression models for forecasting time series data with calendar variation effects", *Proceedings of the 2nd Innovation and Analytics Conference & Exhibition*. 1691, 050026. AIP Publishing.
- Taylor, J. W., (2000), "A Quantile Regression Neural Network Approach to Estimating the Conditional Density of Multiperiod Returns", *Journal of Forecasting*, Vol.19, hal. 299-311
- Taylor, J. W., dan Bunn, D. W., (1999), "Investigating Improvements in the Accuracy of Prediction Interval for Combinations of Forecast: A Simulation Study", *International Journal of Forecasting*, Vol 15. hal. 325-339
- Walpole, R. E., Myers, R.H., Myers, S.L., dan Ye, K., (2012), *Probability and Statistics for Engineers and Scientists*, 9th ed. Prentice Hall, Boston.
- Wei, W. S., (2006), *Time Series Analysis: Univariate and Multivariate Methods* (2nd ed.). Pearson Education, Inc. hal 109-164
- Zhang, G. P., (2003), "Time series forecasting using a hybrid ARIMA and neural network model", *Neurocomputing*, 50, hal. 159-175.
- Zhang, G. P., dan Berardi, V. L., (1998), "An investigation of neural networks in thyroid function diagnosis", *Health Care Management Science*, Vol.1, No.1, hal. 29-37.

*“Halaman ini sengaja dikosongkan”*

## Lampiran I : Studi Simulasi

### A. Data Simulasi Skenario 1, 2, 3 dan 4

t	Y1	Y2	Y3	...	Y20
1	7,414563	8,142427	7,414563	...	5,298602
2	11,07822	12,79197	11,07822	...	4,192827
3	13,59268	12,93672	13,59268	...	10,77629
⋮	⋮	⋮	⋮	⋮	⋮
144	46,88022	51,18799	51,1284	...	23,34318

### B. Syntax Simulasi ARIMAX, ARIMAX-QR, QRNN

```

set.seed(1)
mydata1=read.table("D:/MSC/SEMESTER 4/
THESISKU/Cu pastikan/HASIL/SIMULASI/
Validasi/Y_Simulasi.txt", header=TRUE)
mydata2=read.csv("X_Simulasi.csv",header=
TRUE, sep=";")
Y=as.ts(mydata1[1:132,1])
X=as.matrix(mydata2[1:132,1:21])
model.tsr=lm(Y~X-1)
summary(model.tsr)
fits.tsr.training=as.ts(model.tsr$fitted.values)
res.tsr.training=as.ts(model.tsr$residuals)
X=as.matrix(mydata2[133:144,1:21])
new=data.frame(X=mydata2[133:144,1:21])
fore.tsr=predict(model.tsr,new)
Box.test(res.tsr.training,lag=6)
ks.test(res.tsr.training,"pnorm",mean=mean(re
s.tsr.training),sd=sd(res.tsr.training))
library(FinTS)
hasil.simulasi=matrix(0,12,2)
colnames(hasil.simulasi)=c('chi-sq','p-value')
for (i in 1:12)
{
LM.simulasi=ArchTest(res.tsr.training,lags=i)
hasil.simulasi[i,1]=LM.simulasi$statistic
hasil.simulasi[i,2]=LM.simulasi$p.value
}
hasil.simulasi
#ARIMA
library(forecast)
library(lmtest)
library(tseries)
acf(res.tsr.training,lag.max=48)
pacf(res.tsr.training,lag.max=48)
adf.test(res.tsr.training)

model.arima=arima(res.tsr.training,order=
c(1,0,0),include.mean=FALSE)
coeftest(model.arima)
fits.arima.training=fitted.values(model.ari
ma)
res.arima.training=residuals(model.arima)
fits.arimax=fits.tsr.training+fits.arima.trai
ning
fore.arima=predict(model.arima,
n.ahead=12)
fore.arimax=as.ts(fore.tsr+fore.arima$pre
d)
et.in=abs(as.ts(Y)-fits.arimax)
et2.in=et.in^2
et.out=abs(mydata1[133:144,1]-
fore.arimax)
et2.out=et.out^2
pt.in=abs(100*et.in/as.ts(Y))
pt.out=abs(100*et.out/mydata1[133:144,1
])
RMSE.in.arimax=sqrt(mean(et2.in))
RMSE.out.arimax=sqrt(mean(et2.out))
MdAE.in.arimax=median(et.in)
MdAE.out.arimax=median(et.out)
MdAPE.in.arimax=median(pt.in)
MdAPE.out.arimax=median(pt.out)
hasil.training=cbind(RMSE.in.arimax,Md
AE.in.arimax,MdAPE.in.arimax)
hasil.testing=cbind(RMSE.out.arimax,Md
AE.out.arimax,MdAPE.out.arimax)
pred=data.frame(c(fits.arimax,fore.arimax
))

```

## Lampiran I (Lanjutan)

### C. Syntax Simulasi ARIMAX-QR

```
#ARIMAX-QR
library(quantreg)
fits_Y1=as.ts(pred)
xreal=cbind(fits_Y1)
xreal=as.matrix(xreal)
x=xreal[1:132,]
xdata=as.matrix(cbind(x))
x=xdata[1:132,1:ncol(xdata)]
arimax.qr=rq(Y~x-1,c(0.025,0.05,0.50,0.95,0.975))
summary(arimax.qr,se="iid")
resiarimax.qr=residuals(arimax.qr)
fittedarimax.qr=as.matrix(fitted(arimax.qr))
x=as.matrix(xreal[133:144,1:ncol(xreal)])
x.testing=data.frame(x=xreal[133:144,1:ncol(xreal)])

fore.arimax.qr=predict(arimax.qr,x.testing)
fittedarimax.qr=as.ts(fittedarimax.qr)
fore.arimax.qr=as.ts(fore.arimax.qr)
et.in.arimaxqr=abs(Y-fittedarimax.qr)
et2.in.arimaxqr=et.in.arimaxqr^2
et.out.arimaxqr=abs(mydata1[133:144,1]-fore.arimax.qr)
et2.out.arimaxqr=et.out.arimaxqr^2
pt.in.arimaxqr=abs(100*et.in.arimaxqr/Y)
pt.out.arimaxqr=abs(100*et.out.arimaxqr/mydata1[133:144,1])
RMSE.in.arimaxqr=sqrt(mean(et.in.arimaxqr))
RMSE.out.arimaxqr=sqrt(mean(et.out.arimaxqr))
MdAE.in.arimaxqr=median(et.in.arimaxqr)
MdAE.out.arimaxqr=median(et.out.arimaxqr)
MdAPE.in.arimaxqr=median(pt.in.arimaxqr)
MdAPE.out.arimaxqr=median(pt.out.arimaxqr)
hasil.training.arimaxqr=cbind(RMSE.in.arimaxqr,MdAE.in.arimaxqr,MdAPE.in.a
rimaxqr)
hasil.testing.arimaxqr=cbind(RMSE.out.arimaxqr,MdAE.out.arimaxqr,
MdAPE.out.arimaxqr)
hasil.training.arimaxqr
hasil.testing.arimaxqr
```

## Lampiran I (Lanjutan)

### D. Syntax Simulasi QRNN

```
#1 input ih
Y=mydata1[1:144,1]
fits_Y1=as.ts(pred)
x=as.matrix(fits_Y1)
xtrain=as.matrix(x[1:132])
xtest=as.matrix(x[133:144])
y=as.matrix(Y)
ytrain=as.matrix(y[1:132])
ytest=as.matrix(y[133:144])
library(qrnn)
RMSE.training=matrix(0,15,1)
MAE.training=matrix(0,15,1)
MdAE.training=matrix(0,15,1)
MAPE.training=matrix(0,15,1)
MdAPE.training=matrix(0,15,1)
RMSE.testing=matrix(0,15,1)
MAE.testing=matrix(0,15,1)
MdAE.testing=matrix(0,15,1)
MAPE.testing=matrix(0,15,1)
MdAPE.testing=matrix(0,15,1)
for (i in 1:15)
{
  set.seed(123456789)
  w.qrnn=qrnn.fit(xtrain, ytrain,n.hidden = i, tau =0.5, iter.max = 1000,n.trials = 1,
  lower = 0)
  fits.qrnn=qrnn.predict(x = xtrain, w.qrnn)
  et.in=abs(ytrain-fits.qrnn)
  pt.in=abs(100*et.in/ytrain)
  et2.in=et.in^2
  RMSE.training[i]=sqrt(mean(et2.in))
  MAE.training[i]=mean(et.in)
  MdAE.training[i]=median(et.in)
  MAPE.training[i]=mean(pt.in)
  MdAPE.training[i]=median(pt.in)
  fore.qrnn=qrnn.predict(x = xtest, parms = w.qrnn)
  et.out=abs(ytest-fore.qrnn)
  pt.out=abs(100*et.out/ytest)
  et2.out=et.out^2
  RMSE.testing[i]=sqrt(mean(et2.out))
  MAE.testing[i]=mean(et.out)
  MdAE.testing[i]=median(et.out)
  MAPE.testing[i]=mean(pt.out)
  MdAPE.testing[i]=median(pt.out)
}
hasil.training=cbind(RMSE.training,MAE.training,MdAE.training,
MAPE.training,
MdAPE.training,sMAPE.training,sMdAPE.training)
hasil.testing=cbind(RMSE.testing,MAE.testing,MdAE.testing,MAPE.testing,
MdAPE.testing)
```



## Lampiran I (Lanjutan)

### E. Estimasi Parameter Model ARIMAX Skenario 2

Variabel	Estimasi	T	<i>P-value</i>
$T$	0,085	0,008	0,000
$M_{1,t}$	4,171	1,078	0,000
$M_{2,t}$	4,75	1,081	0,000
$M_{3,t}$	5,459	1,084	0,000
$M_{4,t}$	5,144	1,088	0,000
$M_{5,t}$	4,024	1,091	0,000
$M_{6,t}$	2,968	1,115	0,000
$M_{7,t}$	-0,265	1,174	0,822
$M_{8,t}$	-1,252	1,179	0,291
$M_{9,t}$	-1,723	1,21	0,157
$M_{10,t}$	-1,099	1,222	0,371
$M_{11,t}$	-0,065	1,15	0,955
$M_{12,t}$	1,35	1,116	0,229
$V_{1,t}$	1,727	2,426	0,478
$V_{2,t}$	0,265	1,983	0,894
$V_{3,t}$	1,866	2,002	0,354
$V_{4,t}$	-0,944	1,982	0,635
$V_{1,t-1}$	-2,546	2,441	0,299
$V_{2,t-1}$	1,772	1,991	0,375
$V_{3,t-1}$	2,051	1,989	0,305
$V_{4,t-1}$	1,265	1,976	0,523
$w_1$	0,289	0,084	0,000

## Lampiran I (Lanjutan)

### F. Estimasi Parameter Model ARIMAX-QR Skenario 3

Variabel	Estimasi	t	<i>P-value</i>
$T$	0,085	0,008	0,000
$M_{1,t}$	4,171	1,078	0,000
$M_{2,t}$	4,75	1,081	0,000
$M_{3,t}$	5,459	1,084	0,000
$M_{4,t}$	5,144	1,088	0,000
$M_{5,t}$	4,024	1,091	0,000
$M_{6,t}$	2,968	1,115	0,000
$M_{7,t}$	-0,265	1,174	0,822
$M_{8,t}$	-1,252	1,179	0,291
$M_{9,t}$	-1,723	1,21	0,157
$M_{10,t}$	-1,099	1,222	0,371
$M_{11,t}$	-0,065	1,15	0,955
$M_{12,t}$	1,35	1,116	0,229
$V_{1,t}$	1,727	2,426	0,478
$V_{2,t}$	0,265	1,983	0,894
$V_{3,t}$	1,866	2,002	0,354
$V_{4,t}$	-0,944	1,982	0,635
$V_{1,t-l}$	-2,546	2,441	0,299
$V_{2,t-l}$	1,772	1,991	0,375
$V_{3,t-l}$	2,051	1,989	0,305
$V_{4,t-l}$	1,265	1,976	0,523
$w_1$	0,289	0,084	0,000

## Lampiran I (Lanjutan)

### G. Estimasi Parameter Model QRNN Skenario 4

Variabel	Estimasi	T	<i>P-value</i>
$T$	0,085	0,008	0,000
$M_{1,t}$	4,171	1,078	0,000
$M_{2,t}$	4,75	1,081	0,000
$M_{3,t}$	5,459	1,084	0,000
$M_{4,t}$	5,144	1,088	0,000
$M_{5,t}$	4,024	1,091	0,000
$M_{6,t}$	2,968	1,115	0,000
$M_{7,t}$	-0,265	1,174	0,822
$M_{8,t}$	-1,252	1,179	0,291
$M_{9,t}$	-1,723	1,21	0,157
$M_{10,t}$	-1,099	1,222	0,371
$M_{11,t}$	-0,065	1,15	0,955
$M_{12,t}$	1,35	1,116	0,229
$V_{1,t}$	1,727	2,426	0,478
$V_{2,t}$	0,265	1,983	0,894
$V_{3,t}$	1,866	2,002	0,354
$V_{4,t}$	-0,944	1,982	0,635
$V_{1,t-1}$	-2,546	2,441	0,299
$V_{2,t-1}$	1,772	1,991	0,375
$V_{3,t-1}$	2,051	1,989	0,305
$V_{4,t-1}$	1,265	1,976	0,523
$w_1$	0,289	0,084	0,000

**Lampiran II : Data *Inflow* dan *Outflow* Uang Kartal BI**

**A. Data *Inflow* Uang Kartal BI NTT**

TAHUN	BULAN											
	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
2005	284,018	204,273	215,062	161,305	174,083	186,258	200,855	237,299	193,426	172,811	226,094	265,151
2006	313,663	236,409	214,668	207,097	227,850	226,496	263,180	307,035	267,150	238,066	288,708	109,137
2007	98,613	225,577	156,733	142,234	96,319	97,740	105,309	88,815	107,352	60,590	119,131	72,943
2008	196,337	246,451	94,641	73,416	66,654	47,836	96,832	90,294	79,536	153,669	69,863	76,137
2009	260,892	192,725	158,156	73,096	41,010	115,071	129,037	118,855	56,379	83,746	110,760	111,965
2010	315,961	127,554	156,965	158,541	180,235	128,987	145,684	136,573	111,860	117,169	114,234	134,727
2011	354,261	107,557	212,873	153,743	166,545	134,876	133,657	143,062	239,392	168,545	181,680	129,890
2012	520,213	400,400	210,346	188,739	154,619	96,605	220,527	274,835	181,931	182,313	189,999	113,430
2013	740,800	370,224	250,110	247,049	214,333	153,796	150,959	462,665	157,171	216,324	123,908	86,434
2014	764,941	352,593	254,295	317,807	211,539	208,869	157,176	359,113	250,536	218,972	225,629	190,925
2015	1.003,576	462,500	337,903	165,651	164,583	161,861	396,634	229,439	214,785	160,914	185,588	178,984
2016	938,194	517,691	376,993	260,967	269,408	207,536	450,856	239,971	253,537	207,459	298,385	189,803

## Lampiran II(Lanjutan)

### B. Data *Outflow* Uang Kartal BI NTT

TAHUN	BULAN											
	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
2005	183,918	146,412	214,153	180,347	257,173	302,606	289,545	228,545	336,199	378,057	297,568	403,202
2006	235,128	177,831	247,522	225,951	459,881	285,051	356,627	281,502	283,377	388,375	367,358	700,902
2007	343,173	52,494	93,537	144,835	139,756	338,605	172,875	84,679	249,207	221,080	202,746	536,550
2008	169,036	33,105	167,493	97,266	134,892	342,754	168,243	102,698	431,721	103,409	215,378	627,087
2009	98,098	28,809	52,715	52,038	104,839	383,824	196,076	125,131	117,499	111,357	256,226	670,813
2010	57,217	52,125	65,522	133,078	206,911	319,737	358,099	182,944	249,957	162,061	350,625	852,149
2011	51,915	87,598	136,946	201,885	236,522	273,298	471,768	400,407	174,686	313,108	305,788	1.040,095
2012	61,538	86,315	138,960	292,041	266,134	573,746	429,300	452,292	293,658	324,027	318,017	1.023,486
2013	87,196	122,258	226,774	202,746	407,947	389,717	682,191	313,062	363,362	310,825	335,768	1.274,589
2014	43,764	83,993	194,300	225,196	226,747	369,033	851,358	163,178	335,747	436,574	507,032	1.243,578
2015	92,781	73,751	188,914	322,082	213,131	391,003	857,891	383,109	446,067	488,091	527,262	1.575,028
2016	51,368	132,181	150,091	274,869	391,988	1.016,826	534,493	397,312	411,479	470,338	423,455	1.368,682

## Lampiran II (Lanjutan)

### C. Data *Inflow* Uang Kartal BI Nasional

TAHUN	BULAN											
	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
2005	19170,9	19694,37	23903,66	23713,04	24371,14	27204,09	29426,94	26574,88	31313,95	51884,44	16041,43	36411,01
2006	23357,44	22560,46	29927,81	24823,78	27253,83	29898,24	28946,09	24981,13	30690,25	41551,54	19324,97	34506,16
2007	6813,03	8338,815	10809,95	13339,74	14619,28	17512,16	11009,25	13090,25	19877,04	30969,13	12448,6	36816,68
2008	6879,517	10813,05	11851,08	15291,83	16937,53	23602,25	14323,49	13257,94	54795,24	4241,015	12079,58	41705,49
2009	5053,094	6525,824	13308,1	16965,04	11671,55	22573,14	13486,98	12670,25	44504,29	6924,642	20258,96	31199,19
2010	6299,189	9551,917	9456,626	17077,43	19096,72	19096,83	21643,5	34789,52	33530,53	13492,22	20477,32	42397,51
2011	7477,493	10645,37	18559,37	26590,58	24826,2	28693,28	31677,89	80207,17	11133,4	25290,3	25152,7	56595,28
2012	12626,32	17854,75	31635,2	32145,01	32483,9	43761,26	39761,43	68236,88	16839,93	33012,17	32780,25	67698,62
2013	12657,25	25560,88	35962,53	24320,17	40306,1	36345,48	86486,93	48139,53	28762,2	37583,59	38867,79	74184,8
2014	21171,93	22820,67	36144,57	33985,32	40392,05	37729,27	116788,2	15790,84	33649,56	42945,98	37073,86	72807,73
2015	15556,36	26956,98	32329,15	51238,51	38657,28	57973,71	110998	26510,12	39151,03	39231,94	41339,55	85515,64
2016	18323,55	29733,62	35793,85	44517,84	57555,98	137875,8	35082,5	32721,56	51518,15	38017,63	48056,03	80195,11


## Lampiran II (Lanjutan)

### D. Data *Outflow* Uang Kartal BI Nasional


TAHUN	BULAN											
	JAN	FEB	MAR	APR	MAY	JUN	JUL	AUG	SEP	OCT	NOV	DEC
2005	26379,18	22950,81	24630,62	21741,53	23899,89	22403,64	25858,59	25936,97	25413,6	23479,89	45201,24	26608,29
2006	31326,18	27707,57	26169,1	25441,34	23884,09	22604,9	25202,46	27854,84	24121,29	27938,56	32975,42	9715,042
2007	26604,92	12335,25	10098,31	9929,053	8987,46	7698,026	11592,77	9801,059	7746,168	26011,08	16089,1	7295,141
2008	25305,14	16644,17	9992,228	12061,23	10023,82	9435,538	13995,79	13081,31	9895,375	41405,83	13076,28	9659,619
2009	32555,42	17958,7	12247,64	13536,01	10720,63	9688,88	15931,62	11018,62	15126,39	33675,48	10119,63	9884,58
2010	27308,31	12299,5	14392,32	14289,6	10430,82	12735,19	16884,2	14607,22	40543	19570,57	14079,97	13778,44
2011	22848,58	17945,53	24525,1	17349,97	19562,81	18582,49	21024,85	15430,94	66032,35	25097,45	26789,74	18127,05
2012	40513,38	29441,9	25357,24	24555,04	28494,42	23635,07	30495,92	47204,3	37873,78	26295	32452,87	19852,1
2013	57542,5	33378,6	28552,53	29705,23	29204,26	27538,9	27554,18	84910,29	31821,3	34331,86	31860,08	20405,78
2014	62709,81	39258,36	30476,89	33048,53	29515,82	33339,88	17222,3	103217,6	36847,94	39381,11	34027,55	25115,11
2015	72243,25	33300,78	35383,43	33642,75	34158,8	36347,39	78493,54	51864,96	35226,97	37647,16	35493,06	25930,8
2016	76685,06	47133,93	38547,85	33229,14	43014,46	30720,69	108976,1	45116,46	43946,13	42244,65	39790,58	35121,16

### Lampiran III : Uji Heteroskedastisitas dan Nonlinearitas data

#### A. Boxplot *Inflow* dan *Outflow* Uang Kartal BI Provinsi NTT



#### B. Boxplot *Inflow* dan *Outflow* Uang Kartal BI Nasional



#### C. Uji Nonlinearitas Data *Inflow* Uang Kartal BI Provinsi NTT

Teraesvirta Neural Network Test  
data: Y1 and Y  
X-squared = 0.86923, df = 2, p-value = 0.6475

Teraesvirta Neural Network Test  
data: Y1,Y2,Y7 and Y  
X-squared = 9.017, df = 16, p-value = 0.9127

#### D. Uji Nonlinearitas Data *Outflow* Uang Kartal BI Provinsi NTT

Teraesvirta Neural Network Test  
data: Y1 and Y  
X-squared = 40.647, df = 2, p-value = 1.492e-09

Teraesvirta Neural Network Test  
data: Y1,Y2,Y7 and Y  
X-squared = 71.824, df = 16, p-value = 4.771e-09



### Lampiran III (Lanjutan)

#### E. Uji Nonlinearitas Data *Inflow* Uang Kartal BI Nasional

Teraesvirta Neural Network Test data: Y1 and Y X-squared = 6.5974, df = 2, p-value = 0.03693
Teraesvirta Neural Network Test data: Y1,Y2,Y7 and Y X-squared = 38.965, df = 16, p-value = 0.0011

#### F. Uji Nonlinearitas Data *Outflow* Uang Kartal BI Nasional

Teraesvirta Neural Network Test data: Y1 and Y X-squared = 23.115, df = 2, p-value = 9.562e-06
Teraesvirta Neural Network Test data: Y1,Y2,Y7 and Y X-squared = 110.7, df = 16, p-value = 3.331e-16

## Lampiran IV : Syntax Prorgam SAS 9.1

### A. Model Regresi Time Series

```
data inflow;
input y1 t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 C1t C2t C3t C4t
C1t1 C2t1 C3t1 C4t1 ;
datalines;
.
.
.
;
proc arima data = inflow;
identify var=y1 crosscorr=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11
M12 C1t C2t C3t C4t C1t1 C2t1 C3t1 C4t1 ) nlag=24;
run;
estimate p=(0) q=(0) input=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11
M12 C1t C2t C3t C4t C1t1 C2t1 C3t1 C4t1) noconstant method=cls;
forecast out = inflow lead=12 printall;
outlier maxnum = 132 alpha=0.00135;
run;
var residual;
run;
proc export data=work.inflow
outfile='D:\arimax.csv'
dbms=csv
replace;
run;
```

### B. Model ARIMA

```
data inflow;
input RESIy1;
datalines;
.
.
.
;
proc arima data = inflow;
identify var=RESIy1 nlag=48;
run;
estimate p=(1)(12) q=(0)(0) noconstant method=cls;
forecast out = inflow lead=12 printall;
run;
proc univariate data=inflow normal;
var residual;
run;
proc export data=work.inflow
outfile='D:\arimax\arima.csv'
dbms=csv
replace;
run;
```

## Lampiran IV (Lanjutan)

### C. Model ARIMAX

```
data inflow;
  input y1 t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 C1t C2t C3t
  C4t C1t1 C2t1 C3t1 C4t1;
datalines;
.
.
.
.
;
proc arima data = inflow;
  identify var=y1 crosscorr=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11
  M12 C1t C2t C3t C4t C1t1 C2t1 C3t1 C4t1) nlag=36;
run;
estimate p=(1)(12) q=(0)(0) input=(t M1 M2 M3 M4 M5 M6 M7 M8 M9
M10 M11 M12 C1t C2t C3t C4t C1t1 C2t1 C3t1 C4t1) noconstant
method=cls;          forecast out = inflow lead=12 printall;
outlier maxnum = 132 alpha=0.00135;
run;
proc univariate data=inflow normal;
var residual;
run;
proc export data=work.inflow
  outfile='D:\arimax\arimatsr.csv'
  dbms=csv
  replace;
run;
```

## Lampiran V : Output SAS Model ARIMAX

### A. Estimasi Parameter Regresi Time Series Inflow Uang Kartal BI Provinsi NTT

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
NUM1	1.15065	0.24270	4.74	<.0001	0	t	0
NUM2	371.01737	34.22756	10.84	<.0001	0	M1	0
NUM3	194.68381	34.33324	5.67	<.0001	0	M2	0
NUM4	133.12307	34.44030	3.87	0.0002	0	M3	0
NUM5	98.05661	34.54874	2.84	0.0054	0	M4	0
NUM6	79.55069	34.65853	2.30	0.0236	0	M5	0
NUM7	65.72959	34.76968	1.89	0.0613	0	M6	0
NUM8	102.24494	35.52288	2.88	0.0048	0	M7	0
NUM9	130.55745	37.37621	3.49	0.0007	0	M8	0
NUM10	77.16703	37.55947	2.05	0.0423	0	M9	0
NUM11	74.72416	38.54777	1.94	0.0551	0	M10	0
NUM12	60.34510	38.93581	1.55	0.1240	0	M11	0
NUM13	43.33528	36.66107	1.18	0.2397	0	M12	0
NUM14	89.55344	77.53336	1.16	0.2506	0	C1t	0
NUM15	38.16083	63.25006	0.60	0.5475	0	C2t	0
NUM16	33.43336	63.18470	0.53	0.5978	0	C3t	0
NUM17	-6.30430	62.75466	-0.10	0.9202	0	C4t	0
NUM18	81.72273	77.06659	1.06	0.2913	0	C1t1	0
NUM19	-20.13370	63.00163	-0.32	0.7499	0	C2t1	0
NUM20	-36.12103	63.60614	-0.57	0.5713	0	C3t1	0
NUM21	122.00038	62.96373	1.94	0.0552	0	C4t1	0

### B. Uji Asumsi Residual Independen Regresi Time Series Inflow Uang Kartal BI Provinsi NTT

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	45.77	6	<.0001	0.342	0.264	0.192	0.159	0.228	0.184
12	95.09	12	<.0001	0.179	0.139	0.171	0.134	0.168	0.459
18	103.54	18	<.0001	0.132	0.094	0.116	0.051	0.108	0.044
24	107.16	24	<.0001	-0.017	-0.025	-0.007	-0.024	0.008	0.143

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W 0.913752	Pr < W	<0.0001	
Kolmogorov-Smirnov	D 0.116966	Pr > D	<0.0100	
Cramer-von Mises	W-Sq 0.432716	Pr > W-Sq	<0.0050	
Anderson-Darling	A-Sq 2.415154	Pr > A-Sq	<0.0050	

### C. Estimasi Parameter Model ARIMA Residual Regresi Time Series Inflow Uang Kartal BI Provinsi NTT

Conditional Least Squares Estimation					
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
AR1,1	0.36145	0.08180	4.42	<.0001	1
AR2,1	0.63425	0.08635	7.34	<.0001	12

## Lampiran V (Lanjutan)

### D. Uji Asumsi Residual Independen ARIMA Inflow Uang Kartal BI Provinsi NTT

Autocorrelation Check of Residuals									
To	Chi-		Pr >	-----Autocorrelations-----					
Lag	Square	DF	ChiSq						
6	8.28	4	0.0820	-0.065	0.174	-0.019	0.045	0.116	0.099
12	10.75	10	0.3775	0.079	0.064	0.070	0.003	0.039	0.021
18	11.77	16	0.7600	0.025	-0.026	0.056	-0.012	0.040	0.021
24	15.00	22	0.8622	-0.068	-0.093	0.016	-0.078	-0.018	0.023
30	19.36	28	0.8866	-0.141	0.010	-0.056	0.012	-0.050	-0.021
36	23.26	34	0.9174	-0.105	0.055	-0.088	-0.006	0.001	-0.017
42	26.43	40	0.9512	0.062	-0.081	-0.040	-0.063	-0.023	0.010
48	29.97	46	0.9675	-0.021	-0.062	-0.019	0.039	-0.104	0.013
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.955387	Pr < W	0.0003					
Kolmogorov-Smirnov	D	0.0792	Pr > D	0.0417					
Cramer-von Mises	W-Sq	0.178426	Pr > W-Sq	0.0098					
Anderson-Darling	A-Sq	1.306682	Pr > A-Sq	<0.0050					

### E. Estimasi Parameter Model ARIMAX Inflow Uang Kartal BI Provinsi NTT

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.36047	0.09027	3.99	0.0001	1	y1	0
AR2,1	0.69522	0.09307	7.47	<.0001	12	y1	0
NUM1	0.79961	0.49519	1.61	0.1093	0	t	0
NUM2	415.96267	62.72901	6.63	<.0001	0	M1	0
NUM3	230.09392	65.30163	3.52	0.0006	0	M2	0
NUM4	186.01572	65.97126	2.82	0.0057	0	M3	0
NUM5	128.42018	66.32275	1.94	0.0554	0	M4	0
NUM6	122.71094	66.45371	1.85	0.0675	0	M5	0
NUM7	119.18945	66.62542	1.79	0.0764	0	M6	0
NUM8	165.43877	67.20324	2.46	0.0154	0	M7	0
NUM9	179.61066	67.99567	2.64	0.0095	0	M8	0
NUM10	131.12783	67.49182	1.94	0.0546	0	M9	0
NUM11	114.06346	67.63342	1.69	0.0946	0	M10	0
NUM12	98.68594	72.62748	1.36	0.1770	0	M11	0
NUM13	106.73626	67.91579	1.57	0.1189	0	M12	0
NUM14	84.45102	57.55535	1.47	0.1452	0	C1t	0
NUM15	60.46865	48.79789	1.24	0.2179	0	C2t	0
NUM16	36.74897	48.47688	0.76	0.4500	0	C3t	0
NUM17	-13.25449	42.82518	-0.31	0.7575	0	C4t	0
NUM18	35.12969	50.70850	0.69	0.4899	0	C1t1	0
NUM19	-17.65387	44.58037	-0.40	0.6929	0	C2t1	0
NUM20	-14.11170	52.26501	-0.27	0.7877	0	C3t1	0
NUM21	93.65721	50.10568	1.87	0.0643	0	C4t1	0

### F. Uji Asumsi Residual Independen Model ARIMAX Inflow Uang Kartal BI Provinsi NTT

Autocorrelation Check of Residuals									
To	Chi-		Pr >	-----Autocorrelations-----					
Lag	Square	DF	ChiSq						
6	8.95	4	0.0625	-0.063	0.167	-0.015	0.041	0.146	0.100
12	10.88	10	0.3669	0.050	0.062	0.075	0.016	0.029	0.021
18	11.78	16	0.7589	-0.007	-0.026	0.053	0.014	0.029	0.037
24	15.01	22	0.8616	-0.053	-0.075	0.048	-0.076	0.055	0.026
30	17.29	28	0.9426	-0.101	0.043	-0.026	0.020	-0.023	0.008
36	19.82	34	0.9748	-0.080	0.076	-0.042	-0.008	0.017	0.006
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.952498	Pr < W	0.0002					
Kolmogorov-Smirnov	D	0.098046	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.216911	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	1.514037	Pr > A-Sq	<0.0050					

## Lampiran V (Lanjutan)

### G. Estimasi Parameter Regresi Time Series Outflow Uang Kartal BI Provinsi NTT

Conditional Least Squares Estimation					Approx		
Parameter	Estimate	Error	t Value	Pr >  t	Lag	Variable	Shift
NUM1	1.64683	0.32383	5.09	<.0001	0	t	0
NUM2	28.97626	45.66795	0.63	0.5271	0	M1	0
NUM3	-16.22266	45.80895	-0.35	0.7239	0	M2	0
NUM4	53.23459	45.95179	1.16	0.2492	0	M3	0
NUM5	83.46313	46.09648	1.81	0.0729	0	M4	0
NUM6	134.22247	46.24297	2.90	0.0045	0	M5	0
NUM7	253.28753	47.25620	5.36	<.0001	0	M6	0
NUM8	284.89506	49.74103	5.73	<.0001	0	M7	0
NUM9	91.35449	49.98253	1.83	0.0703	0	M8	0
NUM10	137.05394	51.28869	2.67	0.0087	0	M9	0
NUM11	135.06157	51.79078	2.61	0.0104	0	M10	0
NUM12	220.14936	48.75188	4.52	<.0001	0	M11	0
NUM13	785.74428	47.31783	16.61	<.0001	0	M12	0
NUM14	-24.05171	102.82570	-0.23	0.8155	0	C1t	0
NUM15	26.57818	84.05960	0.32	0.7525	0	C2t	0
NUM16	153.28418	84.86617	1.81	0.0736	0	C3t	0
NUM17	257.15536	84.00904	3.06	0.0028	0	C4t	0
NUM18	223.54333	103.44849	2.16	0.0329	0	C1t1	0
NUM19	88.36151	84.39107	1.05	0.2974	0	C2t1	0
NUM20	-44.56285	84.30387	-0.53	0.5981	0	C3t1	0
NUM21	32.17305	83.73009	0.38	0.7015	0	C4t1	0

### H. Uji Asumsi Residual Independen Regresi Time Series Outflow Uang Kartal BI Provinsi NTT

Autocorrelation Check of Residuals									
Lag	Square	DF	ChiSq	To	Chi-	Pr >	Autocorrelations-----		
6	27.41	6	0.0001	0.123	0.269	0.168	0.169	0.234	0.025
12	69.01	12	<.0001	0.154	0.120	0.112	0.108	0.015	0.471
24	94.30	24	<.0001	0.077	0.007	0.021	0.004	-0.087	0.267
36	106.69	36	<.0001	-0.022	-0.100	-0.106	-0.067	-0.158	0.049
48	125.46	48	<.0001	-0.115	-0.109	-0.055	-0.121	-0.133	-0.088
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.953342			Pr < W				
Kolmogorov-Smirnov	D	0.08055			Pr > D				
Cramer-von Mises	W-Sq	0.235895			Pr > W-Sq				
Anderson-Darling	A-Sq	1.386627			Pr > A-Sq				

### I. Estimasi Parameter dan Uji Asumsi Residual Independen Model ARIMA Residual Regresi Time Series Outflow Uang Kartal BI Provinsi NTT

Conditional Least Squares Estimation									
Parameter		Estimate	Standard Error	t Value	Approx Pr >  t		Lag		
AR1,1		0.08603	0.07899	1.09	0.2781		1		
AR1,2		0.21343	0.08033	2.66	0.0089		2		
AR1,3		0.56249	0.08320	6.76	<.0001		12		
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.97	3	0.2651	0.015	0.037	0.045	0.110	0.103	0.048
12	5.99	9	0.7405	0.045	0.082	0.066	-0.008	0.013	-0.027
24	17.89	21	0.6562	0.011	0.042	0.052	-0.066	-0.086	0.147
36	31.69	33	0.5321	-0.002	-0.091	-0.155	-0.010	-0.101	0.048
48	39.29	45	0.7115	-0.055	-0.055	0.095	-0.041	-0.063	-0.014
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.96969	Pr < W		0.0048			
Kolmogorov-Smirnov		D	0.070828	Pr > D		0.1008			
Cramer-von Mises		W-Sq	0.108615	Pr > W-Sq		0.0886			
Anderson-Darling		A-Sq	0.744196	Pr > A-Sq		0.0514			

## Lampiran V (Lanjutan)

### J. Estimasi Parameter Model ARIMAX Outflow Uang Kartal BI Provinsi NTT

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
AR1,1	-0.0085854	0.07253	-0.12	0.9060	1	y2	0
AR1,2	0.27717	0.07658	3.62	0.0005	2	y2	0
AR1,3	0.71425	0.07945	8.99	<.0001	12	y2	0
NUM1	1.78954	1.27614	1.40	0.1637	0	t	0
NUM2	157.45334	82.61169	1.91	0.0593	0	M1	0
NUM3	17.82881	82.20422	0.22	0.8287	0	M2	0
NUM4	170.23480	86.00091	1.98	0.0503	0	M3	0
NUM5	112.78767	86.26051	1.31	0.1938	0	M4	0
NUM6	210.68528	87.32207	2.41	0.0175	0	M5	0
NUM7	253.81571	87.47718	2.90	0.0045	0	M6	0
NUM8	374.73057	88.15098	4.25	<.0001	0	M7	0
NUM9	64.29922	89.71841	0.72	0.4751	0	M8	0
NUM10	268.43442	88.26669	3.04	0.0030	0	M9	0
NUM11	1.37051	93.40058	0.01	0.9883	0	M10	0
NUM12	368.06327	90.31683	4.08	<.0001	0	M11	0
NUM13	699.28516	84.71112	8.25	<.0001	0	M12	0
NUM14	-42.00428	66.74250	-0.63	0.5305	0	C1t	0
NUM15	122.91230	58.11487	2.11	0.0367	0	C2t	0
NUM16	168.98061	68.01751	2.48	0.0145	0	C3t	0
NUM17	237.34712	66.17860	3.59	0.0005	0	C4t	0
NUM18	364.87678	75.71828	4.82	<.0001	0	C1t1	0
NUM19	73.02210	63.80496	1.14	0.2550	0	C2t1	0
NUM20	-46.71289	62.70274	-0.74	0.4579	0	C3t1	0
NUM21	12.33563	55.77788	0.22	0.8254	0	C4t1	0

### K. Uji Asumsi Residual Independen Model ARIMAX Outflow Uang Kartal BI Provinsi NTT

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.16	3	0.1043	0.088	0.087	0.083	0.092	0.099	0.065
12	11.67	9	0.2327	0.033	0.137	0.106	-0.056	0.033	-0.054
18	14.77	15	0.4682	0.034	-0.057	0.044	0.054	0.097	-0.040
24	18.44	21	0.6211	-0.022	0.037	0.027	-0.033	-0.052	0.127
30	24.23	27	0.6175	0.034	0.009	-0.147	-0.051	0.047	-0.080
36	31.37	33	0.5482	-0.020	-0.118	-0.096	-0.028	-0.122	0.024
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.983825	Pr < W	0.1194					
Kolmogorov-Smirnov	D	0.063994	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.112981	Pr > W-Sq	0.0786					
Anderson-Darling	A-Sq	0.695093	Pr > A-Sq	0.0718					

## Lampiran V (Lanjutan)

### L. Estimasi Parameter Regresi Time Series Inflow Uang Kartal BI Nasional

Parameter	Conditional Least Squares Estimation				Approx		
	Estimate	Error	t Value	Pr >  t	Lag	Variable	Shift
NUM1	194.03227	23.04832	8.42	<.0001	0	t	0
NUM2	26831.0	3250.4	8.25	<.0001	0	M1	0
NUM3	11899.2	3260.4	3.65	0.0004	0	M2	0
NUM4	9760.1	3270.6	2.98	0.0035	0	M3	0
NUM5	8972.9	3280.9	2.73	0.0073	0	M4	0
NUM6	8195.4	3291.3	2.49	0.0143	0	M5	0
NUM7	7558.4	3301.9	2.29	0.0240	0	M6	0
NUM8	11849.8	3373.4	3.51	0.0006	0	M7	0
NUM9	15231.4	3549.4	4.29	<.0001	0	M8	0
NUM10	7597.6	3566.8	2.13	0.0354	0	M9	0
NUM11	11277.9	3660.7	3.08	0.0026	0	M10	0
NUM12	5055.9	3697.5	1.37	0.1743	0	M11	0
NUM13	2010.3	3481.5	0.58	0.5648	0	M12	0
NUM14	29606.7	7362.9	4.02	0.0001	0	C1t	0
NUM15	25730.9	6006.5	4.28	<.0001	0	C2t	0
NUM16	17530.8	6000.3	2.92	0.0042	0	C3t	0
NUM17	-6624.1	5959.5	-1.11	0.2687	0	C4t	0
NUM18	10585.2	7318.6	1.45	0.1509	0	C1t1	0
NUM19	934.26105	5982.9	0.16	0.8762	0	C2t1	0
NUM20	11724.1	6040.3	1.94	0.0548	0	C3t1	0
NUM21	43884.5	5979.3	7.34	<.0001	0	C4t1	0

### M. Uji Asumsi Residual Independen Regresi Time Series Inflow Uang Kartal BI Nasional

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	202.93	6	<.0001	0.469	0.549	0.514	0.465	0.520	0.450
12	332.11	12	<.0001	0.457	0.371	0.389	0.368	0.361	0.363
24	380.51	24	<.0001	0.121	0.076	0.087	0.031	0.109	0.000
36	392.98	36	<.0001	-0.082	-0.056	-0.058	-0.055	-0.139	-0.157
48	502.72	48	<.0001	-0.231	-0.197	-0.217	-0.196	-0.279	-0.307
Tests for Normality									
Test				--Statistic--		-----p Value-----			
Shapiro-Wilk				W	0.972027	Pr < W	0.0079		
Kolmogorov-Smirnov				D	0.086374	Pr > D	0.0170		
Cramer-von Mises				W-Sq	0.264552	Pr > W-Sq	<0.0050		
Anderson-Darling				A-Sq	1.464236	Pr > A-Sq	<0.0050		

### N. Estimasi Parameter dan Uji Asumsi Residual Independen Model ARIMA Residual Regresi Time Series Inflow Uang Kartal BI Nasional

Conditional Least Squares Estimation									
		Standard		Approx					
Parameter		Estimate		Error		t Value	Pr >  t	Lag	
AR1,1		0.32259		0.08144		3.96	0.0001	2	
AR1,2		0.24145		0.08354		2.89	0.0045	3	
AR1,3		0.22200		0.08606		2.58	0.0110	5	
Autocorrelation Check of Residuals									
To	Chi-	Pr >							
Lag	Square	DF	ChiSq	-----Autocorrelations-----					
6	3.55	3	0.3147	0.082	-0.062	-0.027	0.042	-0.036	0.107
12	8.57	9	0.4782	0.054	-0.049	0.017	0.029	0.121	0.115
24	16.65	21	0.7324	-0.023	-0.037	-0.012	-0.036	0.163	-0.045
36	28.00	33	0.7144	-0.047	0.038	0.092	0.106	-0.074	-0.092
48	39.33	45	0.7101	-0.049	0.023	0.053	0.097	-0.096	-0.140
Tests for Normality									
Test				--Statistic--		----p Value-----			
Shapiro-Wilk				W	0.929363	Pr < W	<0.0001		
Kolmogorov-Smirnov				D	0.092342	Pr > D	<0.0100		
Cramer-von Mises				W-Sq	0.373995	Pr > W-Sq	<0.0050		
Anderson-Darling				A-Sq	2.255655	Pr > A-Sq	<0.0050		



## Lampiran V (Lanjutan)

### O. Estimasi Parameter Model ARIMAX Inflow Uang Kartal BI Nasional

Conditional Least Squares Estimation							
Parameter	Standard		Approx		Lag	Variable	Shift
	Estimate	Error	t Value	Pr >  t			
AR1,1	0.33209	0.08781	3.78	0.0003	2	y3	0
AR1,2	0.28080	0.08904	3.15	0.0021	3	y3	0
AR1,3	0.23737	0.09503	2.50	0.0140	5	y3	0
NUM1	127.16754	62.68532	2.03	0.0450	0	t	0
NUM2	33140.8	4625.6	7.16	<.0001	0	M1	0
NUM3	18563.4	4640.3	4.00	0.0001	0	M2	0
NUM4	16184.8	4682.1	3.46	0.0008	0	M3	0
NUM5	15615.0	4724.0	3.31	0.0013	0	M4	0
NUM6	14828.2	4737.0	3.13	0.0022	0	M5	0
NUM7	14097.9	4781.8	2.95	0.0039	0	M6	0
NUM8	18763.4	4832.2	3.88	0.0002	0	M7	0
NUM9	21522.5	4859.6	4.43	<.0001	0	M8	0
NUM10	13774.0	4884.8	2.82	0.0057	0	M9	0
NUM11	17684.8	4894.5	3.61	0.0005	0	M10	0
NUM12	12334.9	4877.2	2.53	0.0129	0	M11	0
NUM13	9916.3	4852.2	2.04	0.0434	0	M12	0
NUM14	26849.9	4911.2	5.47	<.0001	0	C1t	0
NUM15	28673.7	4008.4	7.15	<.0001	0	C2t	0
NUM16	19006.6	3980.9	4.77	<.0001	0	C3t	0
NUM17	-8317.7	3968.5	-2.10	0.0384	0	C4t	0
NUM18	5646.8	4893.0	1.15	0.2510	0	C1t1	0
NUM19	5904.8	4010.3	1.47	0.1438	0	C2t1	0
NUM20	13675.4	4020.1	3.40	0.0009	0	C3t1	0
NUM21	41410.7	3962.1	10.45	<.0001	0	C4t1	0

### P. Uji Asumsi Residual Independen Model ARIMAX Inflow Uang Kartal BI Nasional

Tes

Autocorrelation Check of Residuals									
Lag	Square	DF	ChiSq	To		Chi-		Pr >	
				-----		-----		-----	
6	4.11	3	0.2495	0.031	-0.078	-0.041	0.041	-0.047	0.131
12	9.41	9	0.4004	0.048	-0.058	0.045	0.048	0.117	0.113
18	12.36	15	0.6513	0.014	-0.026	-0.043	-0.073	0.092	-0.053
24	18.03	21	0.6473	-0.004	-0.038	0.014	0.000	0.175	-0.050
30	21.56	27	0.7595	-0.103	0.018	-0.010	-0.054	0.023	0.081
36	26.49	33	0.7814	-0.026	0.067	0.094	0.072	-0.073	-0.054

Tests for Normality					
Test		--Statistic---		----p Value-----	
Shapiro-Wilk		W	0.919272	Pr < W	<0.0001
Kolmogorov-Smirnov		D	0.101389	Pr > D	<0.0100
Cramer-von Mises		W-Sq	0.435083	Pr > W-Sq	<0.0050
Anderson-Darling		A-Sq	2.613043	Pr > A-Sq	<0.0050

## Lampiran V (Lanjutan)

### Q. Estimasi Parameter Regresi Time Series Outflow Uang Kartal BI Nasional

Parameter	Conditional Least Squares Estimation				Lag	Variable	Shift
	Estimate	Standard Error	t Value	Approx Pr >  t			
NUM1	203.16479	24.94764	8.14	<.0001	0	t	0
NUM2	67.17643	3518.3	0.02	0.9848	0	M1	0
NUM3	3887.7	3529.1	1.10	0.2730	0	M2	0
NUM4	10281.3	3540.1	2.90	0.0044	0	M3	0
NUM5	12405.7	3551.3	3.49	0.0007	0	M4	0
NUM6	13213.9	3562.6	3.71	0.0003	0	M5	0
NUM7	17141.0	3640.6	4.71	<.0001	0	M6	0
NUM8	20406.5	3832.1	5.33	<.0001	0	M7	0
NUM9	6242.7	3850.7	1.62	0.1078	0	M8	0
NUM10	5202.2	3951.3	1.32	0.1907	0	M9	0
NUM11	5468.6	3990.0	1.37	0.1733	0	M10	0
NUM12	11005.4	3755.9	2.93	0.0041	0	M11	0
NUM13	38084.7	3645.4	10.45	<.0001	0	M12	0
NUM14	-3886.0	7921.7	-0.49	0.6247	0	C1t	0
NUM15	17890.2	6476.0	2.76	0.0067	0	C2t	0
NUM16	45271.5	6538.1	6.92	<.0001	0	C3t	0
NUM17	54114.1	6472.1	8.36	<.0001	0	C4t	0
NUM18	42417.4	7969.7	5.32	<.0001	0	C1t1	0
NUM19	22618.8	6501.5	3.48	0.0007	0	C2t1	0
NUM20	3717.1	6494.8	0.57	0.5683	0	C3t1	0
NUM21	4623.5	6450.6	0.72	0.4750	0	C4t1	0

### R. Uji Asumsi Residual Independen Regresi Time Series Outflow Uang Kartal BI Nasional

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	155.39	6	<.0001	0.359	0.516	0.419	0.395	0.506	0.381
12	268.62	12	<.0001	0.475	0.310	0.336	0.263	0.255	0.465
18	299.13	18	<.0001	0.154	0.288	0.140	0.160	0.211	0.073
24	313.93	24	<.0001	0.218	0.019	0.158	-0.017	0.070	0.124
36	323.05	36	<.0001	0.019	-0.107	-0.014	-0.138	-0.076	-0.076
42	352.33	42	<.0001	-0.120	-0.098	-0.191	-0.163	-0.205	-0.152
48	416.20	48	<.0001	-0.203	-0.175	-0.201	-0.263	-0.254	-0.254

Tests for Normality			
Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W 0.975612	Pr < W	0.0177
Kolmogorov-Smirnov	D 0.089613	Pr > D	<0.0100
Cramer-von Mises	W-Sq 0.230895	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq 1.272118	Pr > A-Sq	<0.0050

## Lampiran V (Lanjutan)

### S. Estimasi Parameter dan Uji Asumsi Residual Independen Model ARIMA Residual Regresi Time Series Outflow Uang Kartal BI Nasional

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag				
AR1,1	0.39851	0.08091	4.93	<.0001	2				
AR1,2	0.26408	0.08470	3.12	0.0022	5				
AR2,1	0.40093	0.09273	4.32	<.0001	12				
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	8.51	3	0.0366	0.027	-0.078	0.165	0.063	-0.033	0.150
12	12.97	9	0.1641	0.115	0.091	-0.034	-0.035	0.082	-0.021
18	17.59	15	0.2849	-0.092	0.087	-0.024	-0.084	0.055	-0.061
24	23.07	21	0.3405	0.004	-0.066	0.084	-0.124	-0.071	0.047
30	29.24	27	0.3494	0.088	-0.127	-0.023	0.097	-0.007	-0.055
36	32.43	33	0.4955	0.093	-0.029	0.032	-0.011	0.069	0.050
42	34.92	39	0.6564	-0.037	0.030	-0.028	-0.072	-0.035	0.059
48	39.75	45	0.6933	-0.063	0.033	-0.022	-0.055	-0.110	-0.052
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.971426	Pr < W	0.0070					
Kolmogorov-Smirnov	D	0.067215	Pr > D	0.1482					
Cramer-von Mises	W-Sq	0.124943	Pr > W-Sq	0.0513					
Anderson-Darling	A-Sq	0.844496	Pr > A-Sq	0.0299					

### T. Estimasi Parameter Model ARIMAX Outflow Uang Kartal BI Nasional

Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
AR1,1	0.53558	0.08331	6.43	<.0001	2	y4	0	
AR1,2	0.17136	0.08277	2.07	0.0408	5	y4	0	
AR2,1	0.98083	0.05339	18.37	<.0001	12	y4	0	
NUM1	196.31495	155.77669	1.26	0.2103	0	t	0	
NUM2	18479.1	6695.7	2.76	0.0068	0	M1	0	
NUM3	18763.7	6685.0	2.81	0.0059	0	M2	0	
NUM4	22838.8	7561.3	3.02	0.0032	0	M3	0	
NUM5	22751.8	7524.4	3.02	0.0031	0	M4	0	
NUM6	22967.0	7740.8	2.97	0.0037	0	M5	0	
NUM7	25836.6	7739.1	3.34	0.0012	0	M6	0	
NUM8	28181.4	7742.8	3.64	0.0004	0	M7	0	
NUM9	23960.7	7749.2	3.09	0.0025	0	M8	0	
NUM10	28850.6	7536.1	3.83	0.0002	0	M9	0	
NUM11	-5287.3	8887.7	-0.59	0.5532	0	M10	0	
NUM12	19704.1	7603.4	2.59	0.0109	0	M11	0	
NUM13	34371.0	6731.2	5.11	<.0001	0	M12	0	
NUM14	-6418.5	3655.5	-1.76	0.0820	0	C1t	0	
NUM15	28972.1	3191.7	9.08	<.0001	0	C2t	0	
NUM16	40043.1	4170.9	9.60	<.0001	0	C3t	0	
NUM17	49220.9	3951.8	12.46	<.0001	0	C4t	0	
NUM18	54963.6	4756.6	11.56	<.0001	0	C1t1	0	
NUM19	18478.9	3670.7	5.03	<.0001	0	C2t1	0	
NUM20	-1164.5	3486.8	-0.33	0.7390	0	C3t1	0	
NUM21	1915.8	2935.8	0.65	0.5154	0	C4t1	0	

## Lampiran V (Lanjutan)

### U. Uji Asumsi Residual Independen Model ARIMAX Outflow Uang Kartal BI Nasional

Tes

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.88	3	0.0757	-0.034	-0.021	0.150	-0.002	0.057	0.149
12	8.83	9	0.4532	-0.043	0.082	-0.019	-0.040	-0.025	-0.048
18	10.82	15	0.7655	-0.073	0.002	-0.027	-0.046	-0.049	-0.051
24	17.93	21	0.6534	0.117	-0.061	0.040	-0.011	0.143	-0.069
30	23.15	27	0.6770	0.045	-0.105	-0.032	0.130	-0.002	0.008
36	32.36	33	0.4986	0.098	-0.128	0.104	-0.031	-0.083	0.084
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.97267	Pr < W		0.0092			
Kolmogorov-Smirnov		D	0.100284	Pr > D		<0.0100			
Cramer-von Mises		W-Sq	0.217881	Pr > W-Sq		<0.0050			
Anderson-Darling		A-Sq	1.225305	Pr > A-Sq		<0.0050			

## BIOGRAFI PENULIS



Agnes Ona Bliti Puka, lahir di Duli Pali, Flores Timur, Nusa Tenggara Timur pada 18 April 1988. Putri Bungsu dari keempat bersaudara pasangan Paulus Gole Puka dan Hermina Wunga Witin. Penulis menempuh studi dengan jenjang sebagai berikut : Pada tahun 1995 masuk SDI Klatanlo dan tahun 2001 masuk SMPK Sanctissima Trinitas Hokeng dan lulus pada tahun 2004. Pada tahun yang sama masuk SMAK Bhaktyarsa Maumere.

Kemudian pada tahun 2007 melanjutkan studi pada Jurusan Matematika Fakultas Sains dan Teknik Universitas Nusa Cendana, dan memperoleh gelar sarjana sains (S.Si) pada bulan Februari tahun 2012. Pada tahun 2015, penulis melanjutkan studi pada Program Pascasarjana Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember, Surabaya. Dengan penuh kerendahan hati, penulis mengharapkan saran dan kritik yang konstruktif dari para pembaca. Bagi pembaca yang memiliki saran dan kritik atau ingin berdiskusi dengan penulis dapat disampaikan melalui email [agnes\\_onchu@yahoo.com](mailto:agnes_onchu@yahoo.com)

Surabaya, 24 Juli 2017